

**Diseño del método de estimación de demanda para mejorar el desempeño de un Contact
Center en Barranquilla.**

Edith C. Arteta Corro, Liliana P. García Caraballo, Kristyn M. Guerrero Pinto y María Pertuz

Ufre

Departamento de Ingeniería Industrial, Universidad del Norte

7366-09 Proyecto Final

PhD. Carmenza Luna Amaya

27 de noviembre de 2020

Agradecimientos

Expresamos nuestros más sinceros agradecimientos en primer lugar, a nuestros padres, hermanos, abuelos y compañeros que han confiado en nuestras capacidades por todo su apoyo que de alguna u otra forma contribuyó para obtener el título de Ingeniero Industrial, y por la colaboración en el desarrollo de este proyecto a los docentes de la Universidad del Norte.

Resumen

El presente proyecto tiene como objetivo diseñar el método de estimación de demanda para un Contact Center de Barranquilla basado en la comparación de diferentes técnicas de predicción para mejorar el desempeño de la empresa y puesto en práctica en una línea de servicio de una campaña específica del mismo. Esto como posible solución a las falencias en la programación operativa de la misma y la variación del comportamiento de la demanda que se ha presentado a lo largo del año. Para su consecución fue necesario dividir la investigación en 3 macro etapas metodológicas: contextualización, diseño de la alternativa solución y validación con prueba piloto, en cada una de estas se realizaron actividades acordes con el objetivo de las mismas. El diseño de la alternativa solución implicó analizar el comportamiento de la demanda por la línea de servicio, siendo la línea de pospago la de mayor variabilidad y modelar cada una de las técnicas de predicción investigadas: Suavizamiento exponencial, Box Jenkins, Redes Neuronales y Vectores Autorregresivos, de las cuales se aplicó el modelo ARIMA, ARIMAX y vectores autorregresivos (VAR), para luego seleccionar la que mejor se ajustara al comportamiento de los datos, mediante R Studio. En los resultados obtenidos se comparó el RMSE de cada modelo con el fin de elegir el menor, siendo este el modelo ARIMA (2,1,0) arrojando un RMSE de 5.775,991 llamadas por semana. Es importante mencionar que esta investigación propone ser replicable para cualquier línea de servicio y campaña que presente el mismo inconveniente y que los resultados de los pronósticos esperados se validaron a través de la simulación del proceso de llamadas, con Arena, con el fin de contrastar la realidad vs la predicción obteniendo una desviación/variación del -7,18% y así complementar el método de estimación de demanda con una herramienta con el que la compañía puede valerse para tomar una ventaja competitiva frente a otras empresas que ofrecen los mismo servicios.

Palabras claves: Contact Center, pronóstico, estimación de demanda.

ABSTRACT

This project has the objective to design the demand estimation method for a Contact Center in Barranquilla based on the comparison of different prediction techniques to improve the performance of the company and implemented in a service line of a specific campaign. This as a possible solution to the shortcomings in its operational programming and the variation in the behavior of demand that has occurred throughout the year. To achieve this, it was necessary to divide the research into 3 macro methodological stages: contextualization, design of the alternative solution and validation with a pilot test, in each of these, activities were carried out in accordance with their objective. The design of the alternative solution involved the analysis of the demand's behavior per service line, with the postpaid line being the one with the greatest variability and modeling each of the prediction techniques investigated: Exponential Smoothing, Box Jenkins, Neural Networks and Autoregressive Vectors, of which the ARIMA, ARIMAX and Autoregressive Vectors (VAR) models were applied, and then select the one that best fits the behavior of the data, through R Studio. In the results obtained, the RMSE of each model was compared in order to choose the lowest, this being the ARIMA model (2.1.0) yielding an RMSE of 5.775,991. It is important to mention that this research proposes to be replicable for any service line and campaign that presents the same problem and that the results of the expected forecasts were validated through the simulation of the call process with Arena, in order to contrast reality vs prediction obtaining obtaining the deviation / variation by -7.18% and thus complement the demand estimation method with a tool that the company can use to gain a competitive advantage over other companies that offer the same services.

Keywords: Contact Center, forecasting, demand estimation.

Tabla de Contenido

Capítulo I: Presentación.....	8
Introducción.....	8
1.2 Planteamiento del Problema.....	10
1.2.1 Antecedentes.....	10
1.2.2 Identificación de la Problemática.....	16
1.2.3. Justificación.....	20
1.3 Objetivos Y Resultados Esperados.....	21
1.3.1 Objetivo General.....	21
1.3.2 Objetivos Específicos.....	21
1.3.3. Resultados Esperados.....	21
1.4. Etapas Metodológicas del Proyecto.....	22
1.5. Alcances y Limitaciones del Proyecto.....	23
1.6 Cronograma Propuesto.....	24
2. Capítulo II: Marco de Referencia.....	27
2.1 Marco Conceptual.....	27
2.2. Marco Teórico.....	29
2.2.1 Generalidades de los pronósticos.....	30
2.2.2 Modelo Autorregresivo (AR).....	34
2.2.3. Modelo de Promedio Móvil (MA).....	34
2.2.4. Modelo Autorregresivo de Promedio Móvil (ARMA).....	35
2.2.5. Modelo Autorregresivo Integrado de Promedio Móvil (ARIMA).....	36
2.2.5.1 Algunas extensiones del modelo ARIMA.....	39
2.2.6 Metodología Suavizamiento Exponencial.....	41
2.2.6.1. Modelo de suavizamiento exponencial simple.....	41
2.2.6.2 Modelo de suavizamiento exponencial doble.....	42
2.2.6.3 Modelo de suavizamiento exponencial triple o Holt-Winter.....	43
2.2.7. Vectores autorregresivos (VAR).....	44
2.2.8. Redes Neuronales Artificiales (RNAs).....	45
2.2.8.1 Niveles o capas de una Neurona Artificial.....	48
2.2.9. Media móvil autorregresiva vectorial (VARMA).....	49
2.3. Métricas del error.....	51
2.4. Análisis Bibliográfico.....	52
2.4.1. Suavizamiento exponencial triple o Holt Winters.....	52
2.4.2. Redes Neuronales artificiales.....	53
2.4.3 Modelos ARIMA y ARIMAX.....	54
2.4.4. Modelo autorregresivo vectorial (VAR).....	56
2.4.5. Análisis y criterios de selección.....	57
2.4.6. Selección del método de pronóstico a utilizar.....	60
2.5. Conclusiones.....	61

Capítulo III: Diseño de la Propuesta.....	62
3.3.1 Método de pronóstico ARIMAX.....	75
3.3.2 Método de pronóstico ARIMA.....	83
3.3.3 Método de pronóstico VAR.....	84
3.4 Selección del modelo.....	88
Capítulo IV: Validación y Análisis de los Resultados.....	89
4.1. Validación de pronósticos.....	89
Capítulo 5: Conclusiones y recomendaciones..	91
ANEXOS.....	102

Lista de Figuras

Figura 1.1. Ocupación por línea de servicio de Enero a Agosto de 2020	¡Error! Marcador no definido.
Figura 1.2 Niveles de servicio por la línea de servicio de Enero a Agosto de 2020..	¡Error! Marcador no definido.
Figura 1.3. Serie de tiempo de la demanda diaria de llamadas - Línea Pospago. .	¡Error! Marcador no definido.
Figura 1.4. Serie de tiempo de la demanda diaria de llamadas - Línea Prepago...	¡Error! Marcador no definido.
Figura 1.5. Serie de tiempo de la demanda diaria de llamadas - Línea Televisión....	¡Error! Marcador no definido.
Figura 1.6. Serie de tiempo de la demanda diaria de llamadas - Redes Sociales..	¡Error! Marcador no definido.
Figura 1.7. Diagrama Causa-Efecto de la campaña “XYZ”.	¡Error! Marcador no definido.
Figura 1.8. Diagrama Medios-Fines de la campaña “XYZ”	¡Error! Marcador no definido.
Figura 1.9. Cronograma de actividades.	¡Error! Marcador no definido.
Figura 2.1. Proceso iterativo de la metodología Box y Jenkins.....	39
Figura 2.2. Estructura de una red neuronal artificial.....	48
Figura 2.3. Capas de una red neuronal.....	49
Figura 3.4. Serie de tiempo diario - Línea Prepago.....	66
Figura 3.5. Gráfico de cajas y bigotes mensual - Línea Prepago.....	66
Figura 3.6. Serie de tiempo diario - Línea Pospago.....	68
Figura 3.7. Gráfico de cajas y bigotes mensual. - Línea Pospago.....	69
Figura 3.8 Media y cuartiles por mes - Línea Pospago.....	70
Figura 3.6 Serie de tiempo diario - Línea Televisión.....	71
Figura 3.7. Gráfico de cajas y bigotes mensual. - Línea Televisión.....	73
Figura 3.8. Gráfico de cajas y bigotes mensual. - Línea Redes Sociales.....	73
Figura 3.9. Gráfico de serie de tiempo para cada variable. - Línea Pospago.....	76
Figura 3.10. Gráfico de correlación ACF. - Línea Pospago.....	¡Error! Marcador no definido.
Figura 3.11. Gráfico de correlación PACF. - Línea Pospago	¡Error! Marcador no definido.

Figura 3.12. Gráfico de revisión de los residuales.	¡Error! Marcador no definido.
Figura 3.13. Gráfico de revisión de los residuales para la variable exógena.	81
Figura 3.14. Gráfico de pronósticos del modelo ARIMAX(2,2,0).	82
Figura 3.15. Gráfico de revisión de los residuales para modelo ARIMA (2,1,0).	83
Figura 3.16. Gráfico de pronósticos para modelo ARIMA (2,1,0).	¡Error! Marcador no definido.
Figura 3.17. Resultados de test de granger para la variable Entrante. ..	¡Error! Marcador no definido.
Figura 3.18. Resultados de test de granger para la variable TMO.	¡Error! Marcador no definido.
Figura 3.19. Gráfico de pronóstico para modelo VAR.	¡Error! Marcador no definido.
Figura 4.1. Simulación de proceso de llamadas de línea pospago.	90

Lista de Tablas

Tabla 1.1. Descripción de las etapas metodológicas del proyecto.	¡Error! Marcador no definido.
Tabla 1.2. Cronograma propuesto del proyecto.	¡Error! Marcador no definido.
Tabla 2.1 Técnicas de predicción según criterios de estacionalidad y tendencia.	53
Tabla 2.2. Cuadro comparativo de métodos de pronóstico.	57
Tabla 3.1. Media y cuartiles por mes - Línea Prepago.	¡Error! Marcador no definido.
Tabla 3.2. Media y cuartiles por mes - Línea Pospago.	69
Tabla 3.3. Media y cuartiles por mes - Línea Televisión.	71
Tabla 3.4. Tabla Media y cuartiles por mes - Línea Redes Sociales.	¡Error! Marcador no definido.
Tabla 3.5. Rango Intercuartil por mes.	¡Error! Marcador no definido.
Tabla 3.6. Rango Intercuartil por día de semana.	¡Error! Marcador no definido.
Tabla 3.7. Tabla comparativa entre variables y p-values.	¡Error! Marcador no definido.
Tabla 3.8. Tabla comparativa de resultados de RMSE entre modelos.	¡Error! Marcador no definido.

Capítulo I: Presentación

En este primer capítulo se abordarán los ítems necesarios que se realizaron para llevar a cabo de manera exitosa la identificación de la problemática actual de la empresa, tales como los antecedentes de esta, referencia clave para los autores que permitieron el análisis del panorama general y que a su vez permitieron direccionar y aterrizar el proyecto hacia su objetivo central. Así mismo, mediante un diagrama de causa efecto se explican las raíces de la problemática y a través de un diagrama de medios y fines se abordaron las posibles alternativas de solución. Se explica también la justificación y el impacto que se quiere lograr para la empresa mediante esta investigación. Los objetivos generales y específicos, la metodología a llevar a cabo y los alcances y limitaciones de esta, son también parte de esta primera sección.

Introducción

Gracias a la globalización, a los avances e innovaciones tecnológicas que el mundo le ofrece a las compañías hoy en día, el apoyo de contact centers involucrados en la operación cada vez cobra más importancia en nuestra sociedad. Eran estos, quienes para el siglo XX prestaban un servicio netamente informativo dirigido a un amplio público de clientes. Sin embargo, debido a la crisis de petróleo de 1973 las empresas norteamericanas se vieron en la necesidad de reducir sus costos y encontraron en los centros de llamadas, una estrategia que les permitía ahorrar significativamente en gastos fijos de alquiler de infraestructura, pero sobretodo a optimizar el tiempo de trabajo de sus empleados.

La subcontratación de procesos de negocio, cuyas siglas en inglés hacen referencia a *Business Process Outsourcing (BPO)* constituyen una pequeña infraestructura en costos y

están orientados a las operaciones de los centros de llamadas (USAID, 2008); razón por la cual requieren una ardua planeación operativa que apunte a la consecución de los objetivos de la compañía. Dicha planeación incluye la asignación de recursos del call center, entendiéndose por recurso: pronósticos, agentes, analistas, recursos tecnológicos y no tecnológicos, entre otros.

Así mismo, la gestión de un contact center, centro de llamadas o BPO radica en qué tan eficiente es el sistema, lo que se convierte en una ventaja con respecto a otros sectores empresariales del mercado al poseer éstos métricas medibles y cuantificables, que arrojan resultados significativos y cuyo análisis no solo permite tomar decisiones estratégicas de mejora, sino que también garantizan competitividad. Entendiéndose por competitividad como una etapa en donde la productividad se persigue a toda costa. (Paternina, F. 2011).

No obstante, existe una cantidad finita de indicadores a través de los cuales se pueden obtener los resultados que se buscan, sin embargo, para objeto de este trabajo se han identificado: El nivel de servicio, la eficiencia del sistema y la ocupación de los servidores (agentes operativos) como pilares de la operación del contact center.

Según su definición, se entiende por nivel de servicio al porcentaje de llamadas contestadas antes de determinado tiempo, la eficiencia como la capacidad del Centro BPO para contestar la proyección más la holgura que solicite el cliente y la ocupación como el porcentaje de tiempo que los asesores invierten en atender llamadas.

En este orden de ideas, actualmente, se ha encontrado en un determinado Contact Center de la ciudad de Barranquilla bajos niveles de los indicadores anteriormente mencionados en las distintas líneas de servicio de una campaña “XYZ” en específico, entendiéndose esta última como el cliente o empresa contratista a la que el Contact Center presta el servicio de llamadas. Lo anterior, debido a las falencias que puede estar presentando el área de WorkForce Management o WFM (gestión de fuerza laboral) desde su etapa inicial,

es decir durante su planeación, al momento de determinar el modelo de pronóstico de demanda de llamadas, que afecta de manera directa la planeación operativa de la organización.

Un problema que enfrentan las empresas de este sector, debido al comportamiento errático de la demanda, es el cálculo de pronósticos que es uno de los insumos principales para la planificación y programación de personal que les permite ofrecer a sus clientes un nivel de indicadores objetivo. La empresa actualmente se basa en modelos de media móvil simple y ponderado y considera un histórico de cierta cantidad de semanas para hallar la predicción de llamadas. En la campaña que en el presente trabajo se denomina como “XYZ”, se han identificado bajos niveles en sus indicadores e incumplimiento de resultados esperados, lo que posiblemente también esté ocurriendo con otras campañas de la compañía. Razón por la cual se busca diseñar el método de estimación de demanda para un Contact Center de Barranquilla basado en la comparación de diferentes técnicas de predicción para mejorar el desempeño de la empresa.

1.2 Planteamiento del Problema

1.2.1 Antecedentes

En los últimos años el servicio ofrecido por los contact center ha cobrado más relevancia conforme a las necesidades que enfrentan las empresas debido a la globalización. Sin embargo, pese a la gran ayuda que representa tercerizar dicha operación, sigue siendo un reto para quienes diseñan, planean y ejecutan las estrategias para llevar a cabo la tarea de la mejor manera.

En el Contact Center del presente proyecto, la campaña “XYZ” maneja cuatro principales líneas de servicio de soporte o atención al cliente, las cuales se describen a continuación:

- **Pospago:** atiende llamadas telefónicas relacionadas con contratos de usuarios que han adquirido un plan para su móvil o celular, suspensiones del servicio de este por falta de pago, o cualquier otro factor que esté afectando el plan del usuario como facturaciones, soporte técnico, entre otros.
- **Prepago:** se atienden llamadas relacionadas con recargas para su teléfono móvil y es la línea que presenta mayor cantidad de reclamos por parte de los usuarios actualmente.
- **Televisión:** son llamadas de personas que tienen contratos en casa de internet, telefonía y/o televisión.
- **WhatsApp Móvil y Reclamos:** en esta línea se resuelve cualquier tipo de inconveniente que tengan los usuarios.


La demanda de llamadas entrantes para cada línea de servicio, ha presentado ciertas variaciones repentinas, picos abruptos, bajas en los niveles de ocupación de los agentes, estando en algunos meses hasta debajo del 70% en promedio durante el 2020 para ciertas líneas de servicio (Ver Figura 1.1). Así mismo ocurre con el nivel de servicio, ya que la compañía para la mayoría de sus campañas busca obtener un nivel de servicio promedio igual o superior al 85% y esto no se ha evidenciado, debido a que en algunos meses se presentan niveles promedio de servicio por debajo del 80% en cada una de las líneas de servicio ofrecidas en la campaña (Ver Figura 1.2). Por otro lado, esta es la tercera campaña más grande de la empresa, en la que se manejan alrededor de 200 empleados, siendo esto significativo a nivel de costos de personal e ingresos para la compañía. Lo anterior lleva a intuir, que las prácticas y métodos actuales que se utilizan para predecir la demanda de llamadas en la planificación operativa están afectando el desempeño de la campaña y a su vez de la compañía, y aumenta los esfuerzos que debe ejecutar el área de gestión en tiempo real (GTR), debido a que esta debe planificar y programar el personal en un corto plazo cuando se

Figura 1.1.

Ocupación por línea de servicio de Enero a Agosto de 2020.
 presentan días en los que el plan de día es inconsistente.

Figura 1.2.

Niveles de servicio por la línea de servicio de Enero a Agosto de 2020.





Fuente: Elaboración propia

Teniendo en cuenta lo entrevistado con los analistas de la campaña, el actual modelo de pronóstico de media móvil es un indicio de que ya no se ajusta a las necesidades de la campaña a estudiar y puede ser un foco de alerta para otras campañas en las que pueda estar ocurriendo lo mismo. Este tipo de modelo de pronóstico se ajusta a series con demandas estables, sin tendencias y estacionalidades y suaviza las fluctuaciones de periodos cortos, sin embargo se ha evidenciado que el comportamiento de llamadas no tiene una estabilidad en el tiempo, por el contrario se han detectado estacionalidades que hacen que, a pesar de que el modelo de media móvil se pueda utilizar para cualquier serie temporal, actualmente ya está presentado un problema para la campaña que genera al final inconformidades en el nivel de servicio esperado.

Por otro lado, los altos índices de rotación de agentes del Contact Center que se han

presentado desde 2019, son factores claves que también determinan el cumplimiento de los objetivos de la compañía, o en este caso de la campaña. Como se sabe, el trabajo de agente de call center, no es un cargo que demande habilidades y conocimientos experimentados en un área en específico, por ende, las oportunidades de crecimiento profesionales son limitadas, además las personas lo catalogan como un trabajo temporal y se mentalizan con sólo durar un tiempo muy limitado y corto como agente. Lo anterior hace que, las áreas de Operaciones, WFM y Gestión Humana, realicen un trabajo continuo para reclutar personal en periodos cada vez más cortos, que lo que hacen es aumentar los esfuerzos operativos de estas tres áreas para la consecución de sus objetivos.


En la Figura 1.3 y 1.4, se muestra el comportamiento de la demanda diaria de los meses de Enero a Agosto del año 2020, en la que de manera general se evidencia una caída en la demanda de llamadas diario durante los meses de Febrero y Junio en las líneas de Pospago y Prepago, y un aumento abrupto del tráfico de llamadas e interacciones en las líneas de servicio de Televisión y Redes Sociales respectivamente (Ver Figura 1.5 y 1.6), producto de la situación actual del presente año, es decir la pandemia debido al Covid-19. Aunque, es aún más importante resaltar las notorias diferencias que se presentan entre la cantidad de llamadas proyectadas y la demanda real, y lo que todo esto puede llegar a repercutir en el buen nombre de la empresa prestadora de servicio, debido a que estas fluctuaciones tan alarmantes muestran que la compañía no es capaz de mantener sus indicadores de gestión estables para atraer o mantener sus clientes potenciales, en este caso no es posible mantener un nivel de servicio igual o superior al 85%.

Figura 1.3.*Serie de tiempo de la demanda diaria de llamadas - Línea Pospago**Fuente: Elaboración propia***Figura 1.4.***Serie de tiempo de la demanda diaria de llamadas - Línea Prepago**Fuente: Elaboración propia*

Fuente: Elaboración propia

Figura 1.5.


Serie de tiempo de la demanda diaria de llamadas - Línea Televisión



Fuente: Elaboración propia

Figura 1.6.

Serie de tiempo de la demanda diaria de llamadas - Redes Sociales



Fuente: Elaboración propia

Lo anterior, acompañado de lo que se explicará a continuación sugiere que existe un problema dentro de la construcción de los pronósticos que no se ajustan a los cambios y necesidades que está presentando la demanda de la campaña del presente proyecto y esto hace que los indicadores tanto de ocupación como de nivel de servicio se comporten de

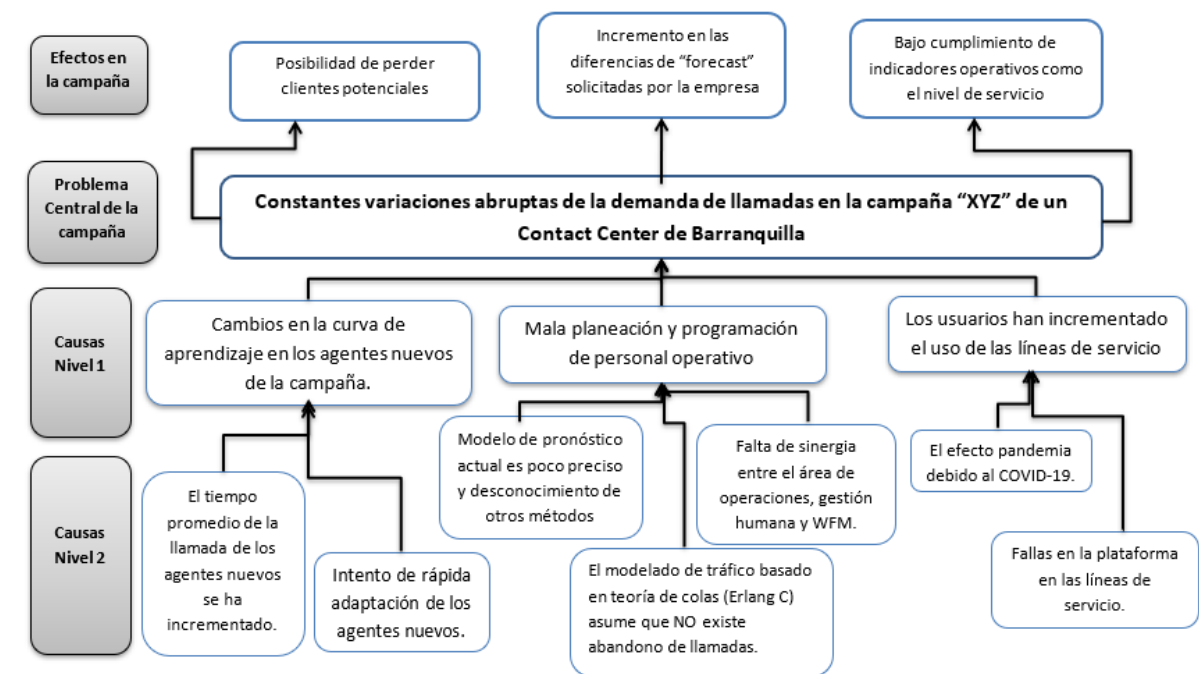
manera inversa.

1.2.2 Identificación de la Problemática

Teniendo en cuenta la información proporcionada por el contact center sobre lo que está ocurriendo con la campaña “XYZ” y los indicadores de ocupación de agentes y nivel de servicio y lo revisado en diversas fuentes bibliográficas y datos de primera mano por parte de la empresa, se decidió realizar un árbol de problemas o diagrama causa-efecto que se muestra en la Figura 1.7, en el que el problema central de la campaña son las constantes variaciones abruptas de la demanda de llamadas en la campaña “XYZ” y se describen los síntomas o causas detectadas que generan los efectos plasmados en el árbol.

Figura 1.7

Diagrama Causa-Efecto de la campaña “XYZ”



Fuente: Elaboración propia

De lo anterior, se describen las principales *causas* de la problemática central identificada, como las siguientes:

Cambios en la curva de aprendizaje en los agentes nuevos de la campaña: esta causa de primer nivel viene dada por dos causas relacionadas con el nuevo personal operativo, es

decir los agentes, que apenas ingresan a la compañía. Si bien es cierto que estos reciben varias capacitaciones entre 2 a 3 semanas dependiendo de las habilidades que se requieran de la persona en el puesto, esto no elimina el hecho de que los nuevos agentes estén en un trabajo constante de adaptarse lo más rápido posible a las metas propuestas por el área de operaciones, lo cual puede ser beneficioso pero a la vez contraproducente ya que hay agentes que por la presión de adaptarse rápido y eficazmente a la compañía, terminan no cumpliendo con lo esperado en cuanto a tiempo promedio de la llamada y tiempo disponible para atender la demanda de llamadas. Por lo tanto, dado que la curva de aprendizaje de los agentes es medida por el tiempo promedio de las llamadas, tiempo hablado, tiempo de espera, entre otros, claramente si el primero de estos tiempos está resultando muy por encima o por debajo de lo esperado afectará la curva de aprendizaje de los agentes nuevos.

Mala planeación y programación del personal operativo: este problema tiene como raíz el modelo de pronóstico actualmente utilizado, el cual es poco preciso y el desconocimiento de otras alternativas de métodos de pronósticos, ya que el eslabón inicial que hace funcionar la gestión del área de WFM, es el de pronósticos de la demanda de llamadas para períodos futuros, por lo que si el modelo de pronóstico actual no se ajusta a los cambios que puede llegar a presentar la demanda, este generará un efecto de “bola de nieve” en toda el área, ya que si los pronósticos están muy alejados de lo que en realidad puede pasar en el futuro, esto afectará directamente la planeación de requerimiento de personal, debido a que puede haber un exceso o escasez de agentes en ciertos periodos de tiempo, lo que a su vez ocasiona que la programación de personal esté basada en una cantidad sobre o sub dimensionada y asimismo la gestión en tiempo real gaste más esfuerzos en ajustar turnos de trabajo o recortar capacitaciones. También que esto tenga un impacto en los costos operativos destinados para la contratación de personal y de igual modo en lo que la compañía percibe monetariamente en sus utilidades por cada llamada no atendida, por cada agente que

disminuye su tiempo productivo y demás que afecten el desempeño de la campaña y a su vez de la compañía.

Los usuarios han incrementado el uso de las líneas de servicio: debido a que en el 2020 ha sido el desarrollo de la pandemia por el Covid-19, esto según los analistas de la campaña, es lo que ha causado principalmente el aumento en la cantidad de llamadas entrantes. Además, se han presentado caídas en las plataformas de las líneas de servicio, incrementando así la posibilidad que una persona vuelva a llamar más de una vez en el mismo día o incluso en la misma franja horaria.

Los principales *efectos* de constantes variaciones abruptas de la demanda de llamadas de la campaña “XYZ” son los siguientes:

Posibilidad de perder clientes potenciales: la imagen de calidad que puede estar dando la compañía al presentar indicadores bajos de cumplimiento, puede afectar la captura de clientes potenciales que estén interesados en contratar al Contact Center, ya que un cliente insatisfecho y más una empresa, puede generar dudas en dichos clientes.

Incremento en las diferencias de “forecast” solicitadas por la empresa contratista: al haber una variación mayor a la esperada entre lo que se pronostica y lo que ocurre en la realidad, hace que la empresa contratista empiece a percibir que lo que predice la compañía para la demanda de llamadas, se esté haciendo de una manera tal que no se está logrando detectar en los pronósticos las fluctuaciones de esta.

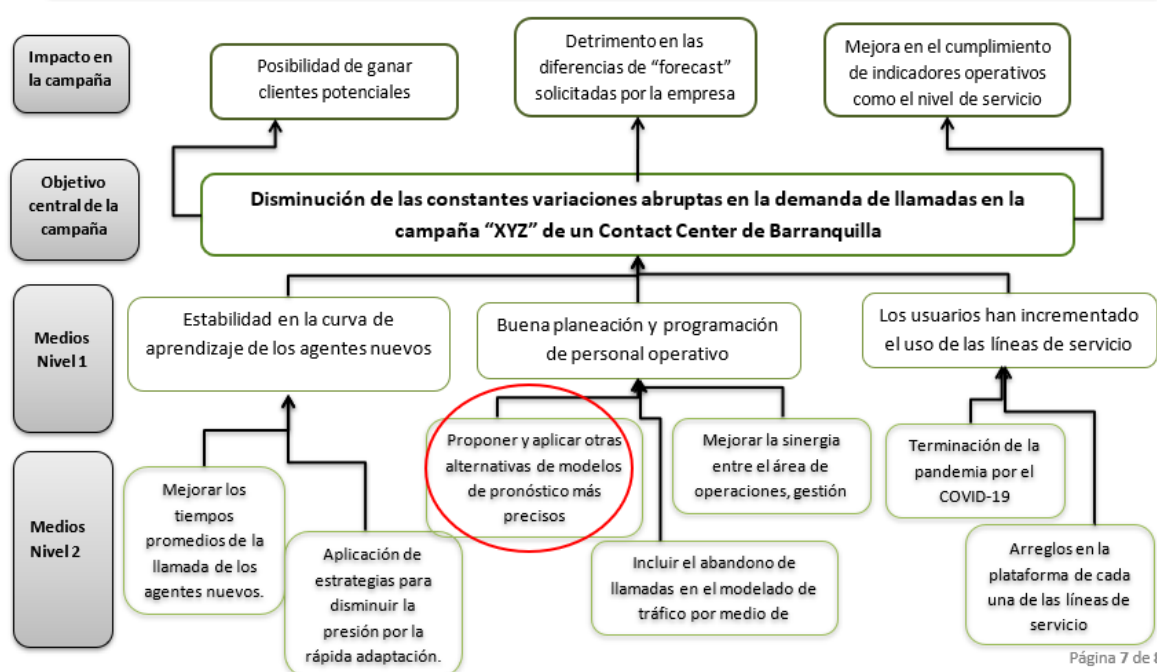
Bajo cumplimiento en los indicadores operativos como el nivel de servicio: este último efecto es clave, ya que, si el desempeño de la campaña se está comportando por debajo de las metas propuestas por la compañía o las áreas directivas de la misma, quiere decir que la campaña no se está alineando a los objetivos globales de la compañía, debido a que el incumplimiento de las metas de una campaña afecta de manera directa la imagen y la competitividad de toda la compañía.

Como se evidencia en el Figura 1.8, en el diagrama se proponen las alternativas de solución (medios) para aliviar la problemática central. Si bien todos estos medios contribuyen a solucionar las constantes variaciones de la demanda de llamadas en la campaña “XYZ”, el alcance del proyecto considera sólo la que está señala en el círculo rojo:

A continuación, se presenta el diagrama de medios y fines que proponen soluciones locales a la problemática central:

Figura 1.8.

Diagrama Medios-Fines de la campaña “XYZ”



Fuente: Elaboración propia

Proponer y aplicar alternativas de modelos de pronóstico más precisos: esta propuesta consiste en ofrecer un modelo pronóstico mucho más preciso y ajustado a las necesidades y al comportamiento actual de la demanda de llamadas de una de las líneas de servicio, con el fin de mejorar los niveles de desempeño de esta y asimismo el desempeño de la campaña, a través de la comparación de otras alternativas de métodos de pronóstico que generen métricas de error en la predicción más bajas, para así poder modelar el proceso de llamadas real y ver el nuevo comportamiento de los indicadores ajustados a pronósticos de

demanda mucho más precisos, que contribuyan a la disminución de las variaciones abruptas de la demanda de llamadas.

1.2.3. Justificación

Una de las ventajas de la industria de los contact center, se centra en la capacidad de recolectar, medir y cuantificar la información de su proceso principal. Sin embargo, contar con altos volúmenes de datos no garantiza un buen nivel de control ni predicción en las operaciones, razón por la cual, se pretende diseñar un método de estimación de demanda que le permita predecir de manera eficaz a la empresa el requerimiento de su producto para posteriormente simular el proceso principal y a través de ciertos indicadores, KPI's o indicadores claves de desempeño, en su traducción, se puedan tomar decisiones y acciones correctivas que permitan un mejor funcionamiento y garanticen mejores resultados dentro de una determinada campaña en la empresa del sector de BPO.

En este orden de ideas, la estrategia presentada en este proyecto puede replicarse en otras campañas que presente este tipo de dificultad en el proceso de predicción y cuyo comportamiento sea similar. No obstante, mantener una buena productividad parcial en la compañía puede causar que los resultados esperados y pactados con un determinado cliente sean satisfactorios, por ende, al ser una estrategia replicable en varias campañas es posible que no solo sea un cliente el que se encuentre satisfecho sino que sea toda la demanda de clientes la que obtenga buenos resultados. Así mismo, esto le permite al Contact Center ser más competitivo en el mercado y atraer clientes potenciales al ofrecer servicios de calidad, con altos indicadores de gestión. Todo gracias a un buen método de estimación de demanda de llamadas.

1.3 Objetivos Y Resultados Esperados

1.3.1 Objetivo General

Diseñar el método de estimación de demanda para un Contact Center de Barranquilla basado en la comparación de diferentes técnicas de predicción para mejorar el desempeño de la empresa.

1.3.2 Objetivos Específicos

1. Hacer el diagnóstico del método de estimación de la demanda actual a través de herramientas informáticas, entrevistas y hallazgos para determinar el comportamiento de los datos.
2. Analizar el comportamiento de la serie de tiempo de la demanda actual de llamadas para identificar la línea de servicio con mayor variabilidad, sus estacionalidades, tendencias y ruidos por medio de R-Studio.
3. Comparar los diferentes modelos de pronóstico a través de la revisión documental para definir los que más se ajustan.
4. Aplicar las metodologías de los modelos de pronóstico referentes a la línea de servicio identificada para seleccionar el modelo que más se ajuste mediante los criterios de selección revisados en la literatura.
5. Validar los pronósticos de demanda seleccionados mediante la simulación del proceso de llamadas en Arena Simulation para el análisis de su desempeño.

1.3.3. Resultados Esperados

- Un modelo de pronóstico ajustado a la demanda que pueda ser replicable en el tiempo para otras campañas del Contact Center.

- Un modelo de simulación que permita visualizar cual sería el comportamiento esperado del pronóstico de llamadas como herramienta para complementar el método de estimación de demanda del Contact Center.

1.4. Etapas Metodológicas del Proyecto

A continuación, se explican detalladamente las etapas del presente proyecto, teniendo en cuenta el objetivo, actividades a realizar y herramientas que permitirán llevar a cabo la misma de manera exitosa.

Tabla 1.1.

Descripción de las etapas metodológicas del proyecto.

Etapas	Objetivo	Actividades	Herramientas
Contextualización	Recopilar información académica y práctica referente al proceso principal realizado por la empresa para definir los conceptos y la teoría a aplicar en el diseño de los modelos de pronóstico mediante diferentes fuentes de información y herramientas tecnológicas.	<ul style="list-style-type: none"> -Revisar fuentes primarias a partir de la información proporcionada por el Contact Center. -Revisar fuentes secundarias entre ellas artículos, libros y revistas relacionadas con indicadores de calidad, pronósticos, simulación de procesos discretos y teoría de colas. -Analizar el comportamiento de la serie de tiempo de la demanda actual de llamadas para identificar estacionalidad, tendencias y ruidos. -Realizar el análisis de las posibles metodologías que se podrían utilizar en el Contact Center para pronosticar la demanda. 	<ul style="list-style-type: none"> -Herramientas tecnológicas como R-Studio. -Bases de datos bibliográficas de la Universidad del Norte. -Datos suministrados por la empresa
		-Identificar los	Herramientas

Diseño de la alternativa de solución	-Ejecutar los pronósticos de la demanda en busca de mitigar la problemática planteada por medio de la herramienta Rstudio.	modelos tentativos que se pueden utilizar en el call center. -Estimar los parámetros necesarios para la creación de los pronósticos. -Ejecutar los diferentes modelos de solución por medio de la herramienta Rstudio. -Aplicar la ponderación de factores para las métricas de error para seleccionar el mejor método de pronóstico.	bibliográficas y el software Rstudio.
Validación y prueba piloto	Comprobar los resultados del pronóstico para ver el comportamiento de los indicadores de desempeño mediante la herramienta Arena Simulation.	-Calcular las distribuciones de probabilidad de cada una de las variables o parámetros que se utilizarán en el modelo de simulación. -Realizar pruebas que permitan validar el alcance del entregable diseñado. -Simular el proceso para corroborar los resultados obtenidos.	Software Arena Simulation y otras herramientas tecnológicas

1.5. Alcances y Limitaciones del Proyecto

Con la realización de este proyecto, se pretende proponer una mejora del desempeño de un Contact Center de la ciudad de Barranquilla, a través de la comparación de modelos de pronósticos que permite seleccionar el más adecuado de acuerdo con las necesidades de la empresa, lo que de manera directa le permitirá a la campaña “XYZ” mejorar algunos indicadores como se espera que sean los niveles de eficiencia, nivel de servicio y ocupación de los agentes que actualmente demuestran una baja gestión y así mismo una buena programación operativa.

Con esto se busca que el área de gestión de fuerza laboral cuente con un método de pronóstico ajustado al comportamiento de la demanda real de dicha campaña de tal manera que garantice mejores resultados dentro de la compañía y disminuyan las reacciones correctivas, implementando en su lugar planes preventivos.

Esta estrategia está orientada a la validación del modelo de pronóstico y a la realización de una prueba piloto del mismo, no abarca su implementación.

Por su parte, dentro de las limitaciones que actualmente se tienen se plantea principalmente la pandemia del Sars-Cov-2 o Covid 19, ya que debido a esta el comportamiento de la demanda de llamadas se ha visto afectada de manera directa y los datos con los cuales partiremos para realizar el pronóstico presentan comportamientos atípicos que pueden agregar ruido y afectar la precisión para llevar a cabo nuestro objetivo principal de ser exactos en los pronósticos.

Por otra parte, se presenta como una limitante la recopilación de la información necesaria ya que la empresa referente solo brinda datos de una campaña en específico, lo que limita a los autores a realizar un análisis más profundo y global del comportamiento de las demás campañas y que posiblemente puedan generar otras alternativas de solución.

1.6 Cronograma Propuesto

A lo largo de esta investigación se espera cumplir con cada una de las siguientes actividades propuestas en las diferentes fechas establecidas con el fin de ser controlar y gestionar el tiempo de ejecución ocupado en cada una de las fases del proyecto para de este modo llegar a construir un modelo de pronóstico que le permitirá a la campaña “XYZ” ser más exacta en sus predicciones, en busca de mejorar sus indicadores de desempeño.


Tabla 1.2.*Cronograma propuesto del proyecto.*

ID	ACTIVIDAD	INICIO	DURACIÓN (Días)	FIN
PROYECTO	Nombre del proyecto	17/08/2020	94	19/11/2020
A1.0	Capítulo I: Presentación	17/08/2020	25	11/09/2020
A1.1	Recolección de datos de procesos actuales	25/08/2020	7	24/08/2020
A1.2	Revisión y documentación de las actividades	2/09/2020	7	1/09/2020
A1.3	Análisis de la información	10/09/2020	7	9/09/2020
A1.4	Entrega Anteproyecto	10/09/2020	1	11/09/2020
B2.0	Capítulo II: Marco de referencia	12/09/2020	29	11/10/2020
B2.1	Redacción marco teórico y conceptual	12/09/2020	15	27/09/2020
B2.2	Construcción modelos de pronóstico	28/09/2020	7	5/10/2020
B2.3	Entrega revisión documentada y avance del diseño	6/10/2020	5	11/10/2020
C3.0	Fase de análisis de resultados	12/10/2020	38	19/11/2020
C3.1	Selección del modelo de pronóstico que mejor se ajuste	12/10/2020	7	19/10/2020
C3.2	Validación por medio de un modelo de simulación	20/10/2020	7	27/10/2020

C3.3	Análisis de los indicadores de desempeño	28/10/2020	7	4/11/2020
C3.4	Creación de póster referente al proyecto	5/11/2020	7	12/11/2020
C3.5	Presentación informe final del proyecto	13/11/2020	6	19/11/2020

Figura 1.9.

Cronograma de actividades



Fuente: Elaboración propia

Teniendo en cuenta cada una de las pautas mencionadas en este primer capítulo para la realización del presente proyecto y los objetivos propuestos, en el siguiente se revisará lo que la literatura actual ha avanzado en términos de métodos de pronósticos, sin dejar de lado los modelos clásicos que ya han sido muy reconocidos a lo largo del tiempo.

2. Capítulo II: Marco de Referencia

En este capítulo se exponen las teorías base que permitieron el desarrollo de la investigación, dentro del cual se incluye el marco conceptual, y el marco teórico. Asimismo, el análisis bibliográfico realizado y las conclusiones de los investigadores cuyas teorías fueron fundamentales para la consecución del objetivo principal. En el marco conceptual se detalla el glosario de palabras que le permiten al lector comprender la terminología y el contexto utilizado a lo largo de toda la investigación. De la misma manera, el marco teórico, que abarca las distintas metodologías revisadas por los autores en la literatura, las cuales sirvieron como base para elegir el mejor modelo que se ajustó a los resultados que se esperaban obtener. Dentro de esta categoría, hemos decidido analizar las metodologías de Box-Jenkins, modelos autorregresivos AR, autorregresivos de promedio móvil ARMA, autorregresivo integrado ARIMA y algunas extensiones, suavizamiento exponencial, simple doble y Holt Winter, Media móvil, y redes neuronales.

Por su parte, el proceso de revisión bibliográfica se desarrolló a partir de la exploración de información, términos, metodologías y conceptos claves para abordar los temas a tratar en el proyecto, los cuales fueron consultados de diferentes fuentes como bases de datos ofrecidas por los servicios virtuales de la Universidad del Norte en su portal web y Google Scholar con el fin de enriquecer los conocimientos en los diferentes temas a explorar como lo son los indicadores de desempeño, las diferentes metodologías de pronósticos y la simulación de procesos discretos.

2.1 Marco Conceptual

Pronóstico: Es un método de estimación de un acontecimiento futuro proyectando datos del pasado y consideraciones subjetivas que se combinan sistemáticamente para lograr la predicción a corto, largo o mediano plazo según se requiera (Everet y Ebert, 1991).

Workforce: Es el activo fundamental de toda organización, el recurso que pone el

movimiento el resto de los factores que intervienen en el proceso productivo. Es uno de los puntos clave para lograr la máxima productividad y calidad en la entidad, ya que constituyen el mayor gasto y la mayor cantidad de problemas administrativos junto con las decisiones directivas más delicadas (Herrera, 2018).

Simulación: Es una metodología que sirve para dar apoyo en la solución de problemas representando en forma real el comportamiento de un sistema de interés dadas ciertas entradas y así poder sacar conclusiones que permitan tomar decisiones que mejoren el sistema en cuestión (Sarabia & Paternina, 2006).

Estacionalidad: Es la repetición sistemática de determinadas variaciones no necesariamente regulares en alguna variable cada cierto periodo de tiempo normalmente igual o menor a un año que afectan las decisiones de los agentes y técnicas de producción disponibles en diferentes ámbitos (Rodríguez & Massa, 2012).

Tendencia: Es la evolución lenta y a largo plazo en el nivel medio de una serie. Se asume que está dada por una función T de t , que es el modelo para estimar (Rodríguez & Massa, 2012).

Error: Es la diferencia numérica entre la demanda pronosticada y la real, es la base para el control, los errores se observan en toda la historia del sistema de pronósticos y existen varios métodos para calcular este proceso, aunque cada uno tiene un significado distinto (Everet y Ebert, 1991).

Indicador de desempeño: Son herramientas de gestión creadas para establecer comparación entre elementos cuantitativos en diferentes combinaciones que se ocupan tanto de los aspectos organizacionales del desempeño, la medición de recursos, los procesos, los productos y el rendimiento que constituyen una herramienta importante en el proceso de evaluación permite tomar decisiones relevantes en el éxito actual y futuro de la organización (Alberto, 2013).

Tráfico de llamadas: Se refiere a el flujo de llamadas realizadas simultáneamente durante un periodo particular de tiempo a través de la red de telecomunicaciones realizadas en un contact center (Prentt,2015).

Tiempo promedio de desempeño AHT: Es un indicador que mide el lapso promedio en el que un agente atiende un servicio en su cálculo se consideran ciertos tiempos documentados en el postproceso de la empresa. Mientras menor sea el AHT mayor es la rentabilidad del servicio es por eso por lo que este indicador requiere toda la atención de los directores de un call center (Prentt,2015).

Nivel de servicio: Es un indicador de desempeño del rendimiento y no del funcionamiento de una empresa. Este indicador debe ser definido en términos de resultados, ponderable y servir a toda la organización en busca de satisfacer al cliente (Bazalar,2016).

Línea de servicio: Es un conjunto consolidado y estandarizado de actividades dedicadas a satisfacer las necesidades de un mercado o área seleccionada ("Línea de servicio (service line) | Área de Vinculación Tecnológica -", 2020).

2.2. Marco Teórico

Como ya se mencionó anteriormente, los pronósticos son métodos de estimación de un acontecimiento que utiliza datos del pasado para tratar de predecir el comportamiento del futuro. Cobran importancia en la medida que son utilizados como base para tomar decisiones en una compañía. Sipper, D (1998) afirma que los pronósticos proporcionan información para tomar mejores decisiones, sin embargo, es necesario conocer de manera detallada el proceso sobre el cual se realizará el mismo. En esta parte de la investigación, se tomaron varios modelos referentes que se ajustan posiblemente al comportamiento de la demanda de llamadas de la campaña de un Contact Center en Barranquilla y se estudió su metodología para luego aplicarla, objetivo que no hubiera sido posible lograr sin antes realizar este análisis de la literatura.

2.2.1 Generalidades de los pronósticos

Definición

Según Villarreal, M (2019) un pronóstico es una estimación cuantitativa o cualitativa de uno o varios factores o variables que conforman un evento futuro con base en información actual o del pasado. Esto quiere decir, que el comportamiento de los datos históricos permite saber aproximadamente cómo se van a comportar los datos del futuro, generando beneficios en sus resultados.

Por su parte, Izar, J (2007) afirma que los pronósticos se basan en datos históricos de la variable que se va a pronosticar, para obtener de ellos proyecciones hacia el futuro, las cuales puede suponerse que sigan una determinada tendencia, o bien cambiar debido a la implementación de planes específicos de operaciones de alguna área en particular. Definición que va acorde con el objetivo de este proyecto al mencionar que durante la planeación se ejecutan los planes enfocados con los objetivos que se planeen, a través de un pronóstico de demanda como herramienta fundamental.

En este orden de ideas, Farrera, A (2013) considera que los pronósticos son utilizados por las compañías de manera implícita o explícita, ya que “la actividad de planeación les exige hacer estimaciones de las variables relevantes en un ambiente cada vez más incierto”, teoría que soporta la realización de esta investigación.

Estas definiciones descritas anteriormente por distintos autores, dan a conocer la importancia y relevancia del papel que juegan los pronósticos en una organización, de manera que permiten la toma de decisiones y en consecuencia, alcanzar los objetivos planteados.

Principios de los pronósticos

Chapman (2006) define como pronóstico aquella técnica que es utilizada para utilizar experiencias pasadas con la finalidad de predecir expectativas del futuro. Así mismo, en su libro planificación y control de la producción sintetiza los principios básicos de estos, los cuales deben ser analizados por todo aquel que desee modelar una técnica de predicción. Estos principios se explican a continuación:

- *Los pronósticos casi siempre son incorrectos:* en este principio se resalta la importancia de qué tan equivocados se espera estar con respecto al pronóstico comparado con la realidad. Las métricas del error pueden permitir este objetivo, y se depende del tamaño de dicho error seleccionado.
- *Los pronósticos son más precisos para grupos o familias de artículos:* este principio sintetiza que un pronóstico puede ser más exacto si se aplica a una familia de productos o una línea de productos que a uno solo en sí, debido a la cancelación de los errores en las agrupaciones.
- *Los pronósticos son más precisos cuando se usan para periodos cortos:* por aquello de la confiabilidad, el autor plantea que “la demanda en periodos futuros más amplios casi siempre resulta menos confiable” p. (18)
- *Los pronósticos deben incluir un error de estimación:* este principio obedece a la implementación de un error de estimación para que un pronóstico sea llevado a cabo de manera eficiente y completa. Va acorde con el principio número 1.
- *No son sustituto de la demanda calculada:* en este apartado el autor sugiere usar la data real ya que siempre y cuando se tenga disponible, no será necesario realizar el cálculo del pronóstico de la demanda.

Modelos estocásticos

Por otra parte, según Box et al., (2013) el tener en cuenta que probablemente no existe un modelo determinístico que logre predecir con total exactitud la variable de interés, es por eso por lo que, en muchos problemas de la economía, ingeniería y otras ciencias, se debe considerar la dependencia del tiempo sobre el fenómeno que se va a pronosticar. Sin embargo, es posible derivar un modelo que puede ser usado para calcular la probabilidad de un valor futuro entre dos límites especificados y es aquí donde se introduce el concepto de *modelo estocástico*.

Jiménez Guerrero et al., (2006) afirman sobre esta metodología que se “parte del hecho de que la serie temporal que se trata de predecir es generada por un proceso estocástico cuya naturaleza puede ser caracterizada mediante un modelo”. Además, Chatfield (1989, como se citó en Jiménez Guerrero et al. 2006), sugiere que la metodología Box-Jenkins se enfoca en encontrar un modelo que matemáticamente reproduzca el comportamiento de una serie de tiempo y se puedan hacer previsiones utilizando el periodo de tiempo anterior correspondiente.

Ahora bien, un tipo de modelo estocástico es el modelo estacionario. Este modelo asume que el comportamiento del proceso de la variable de interés permanece en equilibrio con ciertas propiedades probabilísticas y varía alrededor de un valor medio constante y posee varianza constante. A partir de los modelos estocásticos y estacionarios se derivan los modelos autorregresivos (de sus siglas en inglés “*Autoregressive Models*” o *AR*) y de media móvil (de sus siglas en inglés “*Moving Average*” o *MA*). De estos dos modelos anteriores se derivan los procesos autorregresivos de promedio o media móvil, los cuales son aplicados a series de tiempo univariantes. Sin embargo, cuando ya no se trata de una serie estacionaria por naturaleza, un proceso autorregresivo integrado de promedio móvil (de sus siglas en

inglés “*Autoregressive Integrated Moving Average*” o *ARIMA*). De ellos se explicarán a continuación.

Clasificación de los Modelos de pronósticos

Los modelos de pronóstico se clasifican en cualitativos, series de tiempo, basados en causales y en modelos de simulación. Para cualquiera de ellos, es importante tener en cuenta el horizonte de tiempo ya sea corto, mediano o largo plazo y el entorno. Así mismo, se debe determinar el método, es decir si son procesos cualitativos o cuantitativos siendo estos últimos aquellos que dan resultados matemáticos.

Dentro de los análisis cuantitativos se tienen los modelos de análisis de series de tiempo y modelos causales. Estos modelos, son aquellos que utilizan data histórica para predecir el comportamiento de demandas. Por su parte, los modelos de series de tiempo incluyen las metodologías de Promedio Móvil, Promedio Móvil Ponderado y Suavizamiento Exponencial. Finalmente, dentro de los modelos causales se tiene la regresión lineal dentro de esta clasificación.

Pasos para realizar un modelo de pronóstico

Garcia, H (2014) resume la realización de un modelo de pronóstico en 8 pasos fundamentales, que se describen a continuación:

1. Determinar la utilización del pronóstico, es decir qué se busca conseguir mediante el mismo.
2. Seleccionar a qué se le va a realizar el pronóstico.
3. Determinar el horizonte temporal de este.
4. Seleccionar el método adecuado.
5. Recopilar la información necesaria.

6. Validar el modelo de pronóstico.
7. Realizar el pronóstico.
8. Implementar resultados.

Una vez planteadas las generalidades de los pronósticos, explicada su definición, importancia principios y pasos, es importante explicar aquellos que serán usados en el presente proyecto, los cuales son:

2.2.2 Modelo Autorregresivo (AR)

Hanke, E. y Reitsch, G., (1996) define el modelo autorregresivo con la siguiente estructura general:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t$$

Donde Y_t es la variable dependiente, ϕ_1, ϕ_2, ϕ_p son los coeficientes de regresión lineal o parámetros, p es el número de términos autorregresivos, $Y_{t-1}, Y_{t-2}, Y_{t-p}$ son variables independientes desfasadas un número (p) específico de periodos y ϵ_t es el ruido blanco en el tiempo t o los residuos que representan sucesos aleatorios que no pueden ser explicados por el modelo. Lo anterior se puede denominar un proceso autorregresivo de orden p o $AR(p)$, esto quiere decir que el modelo $AR(p)$ considera que el valor de la serie en el tiempo t depende de los p valores pasados y los coeficientes miden la influencia de las observaciones del pasado en el presente, es decir que a medida que se incrementa el valor de p , la memoria del modelo es mayor y asimismo su dependencia con el pasado.

2.2.3. Modelo de Promedio Móvil (MA)

Siguiendo con lo definido en Hanke, E. y Reitsch, G., (1996), el modelo de promedio móvil sigue la siguiente forma:

$$Y_t = \omega_0 + \omega_1 a_{t-1} + \omega_2 a_{t-2} + \dots + \omega_q a_{t-q} + \epsilon_t$$

Donde Y_t sigue siendo la variable dependiente, $\omega_1, \omega_2, \omega_q$ son los pesos específicos o parámetros que miden la influencia de las perturbaciones pasadas en el presente de la serie, q es el número de términos de la media móvil, $a_{t-1}, a_{t-2}, a_{t-q}$ son los valores previos de los residuos y ϵ_t continúa siendo el ruido blanco en el tiempo t . Este modelo genera pronósticos de la variable dependiente a través de una combinación lineal de errores que ocurrieron en el pasado.

2.2.4. Modelo Autorregresivo de Promedio Móvil (ARMA)

Según Brockwell y Davis, (1991), últimamente, los sistemas autorregresivos (AR), de media móvil (MA) y ARMA han recibido gran atención en una amplia gama de aplicaciones en campos tan diversos como la ingeniería, la física, la economía, etc. Se demostró que eran modelos muy útiles para describir la dinámica de una serie de tiempo.

El modelo de estimación de señales de AR es una excelente herramienta para analizar situaciones en las que el valor presente de una serie de tiempo depende de sus valores precedentes más un choque aleatorio. El uso del modelo MA es para describir tales fenómenos que producen un efecto inmediato (es decir, solo dura por períodos cortos de tiempo). Un tipo más general de sistemas utilizados en el modelado es el modelo ARMA. El poder de ARMA es que puede incorporar términos AR y MA para lograr una mayor flexibilidad en el ajuste de series de tiempo reales (Brockwell y Davis(1991)).

En general, el modelo ARMA para la predicción de series de tiempo se puede resumir en dos pasos: *modelado* y *predicción*. En el primer paso, el *modelado* denota la estimación de los parámetros ARMA basada en los datos a corto plazo en la etapa inicial; en segundo lugar, la *predicción* denota la validación (predicción) de los parámetros ARMA en los datos a largo plazo. AR y MA son los casos especiales del modelo ARMA, que se analizarán a continuación. Dada una serie de tiempo estable y de media cero $\{x_n, n = 1, N\}$, se puede formular una ecuación diferencial aleatoria de la siguiente manera:

Ecuación

$$x(n) + \sum_{i=1}^p a_i x(n-i) = e(n) + b_1 e(n-1) + \dots + b_q e(n-q)$$

Donde $x(n)$ es el elemento de la serie de tiempo $\{x_n\}$ en el tiempo n , a_i ($i = 1, 2, \dots, p$) denota el parámetro AR, b_j ($j = 1, 2, \dots, q$) denota el parámetro MA, $e(n)$ es el elemento de la serie temporal $\{e_n, n = 1, \dots, N\}$, que es la secuencia residual (es decir, ruido blanco discreto), p y q denota el número de órdenes de AR y MA, respectivamente. Por lo tanto, la ecuación diferencial (1) se reconoce como el proceso de ARMA (p, q), que se puede reescribir como:

Ecuación

$$\sum_{i=0}^p a_i x_{n-i} = \sum_{j=0}^q b_j e_{n-j} \quad \text{donde } a_0 = 1, b_0 = 1.$$

2.2.5. Modelo Autorregresivo Integrado de Promedio Móvil (ARIMA)

ARIMA significa Modelos Autorregresivos Integrados de Medias Móviles. De Arce y Mahia (2003)

Corresponde a un proceso estocástico es una sucesión de variables aleatorias Y_t ordenadas, pudiendo tomar t cualquier valor entre Y y Y_n . La siguiente sucesión de variables aleatorias puede ser considerada un proceso estocástico:

$$Y_{-5}, Y_{-4}, Y_{-3}, Y_{-2}, \dots, Y_3, Y_4$$

Cada una de las variables Y_t que configuran un proceso estocástico tendrán su propia función de distribución con sus correspondientes momentos. Así mismo, cada par de esas variables tendrán su correspondiente función de distribución conjunta y sus funciones de distribución marginales. Definimos un modelo como autorregresivo si la variable endógena de un período t es explicada por las observaciones de ella misma correspondientes a períodos

anteriores añadiéndose, como en los modelos estructurales, un término de error. Según De Arce, R. y Mahía, R. (2003).

El término de error de los modelos de este tipo se denomina generalmente ruido blanco cuando cumple las tres hipótesis básicas tradicionales mencionadas al principio del texto:

- Media nula
- Varianza constante
- Covarianza nula entre errores correspondientes a observaciones diferentes

En su forma más general el modelo ARIMA(p,d,q) ARIMA(P,D,Q,)S podría escribirse como:

$$Y_T = \varphi_1 Y_{T-1} + \varphi_2 Y_{T-2} + \dots + \varphi_{Ps+p+Ds+d} Y_{T-Ps-p-sD-d} + \delta + U_T + \theta_{Qs+q} U_{T-sQ-q}$$

Para determinar el orden de los modelos ARIMA, se tienen en cuenta los siguientes instrumentos:

- **Función de autocorrelación simple**

Esta función provee valores de autocorrelación de la serie con sus valores rezagados. También denominada por sus siglas en inglés como ACF (AutoCorrelation Function). La autocorrelación muestral se denota de la siguiente forma en el rezago k o r_k :

$$r_k = \frac{\sum_{t=1}^{n-k} (Y_t - \underline{Y})(Y_{t+k} - \underline{Y})}{\sum_{t=1}^n (Y_t - \underline{Y})^2} \text{ donde, } \underline{Y} = \frac{1}{n} \sum_{t=1}^n Y_t$$

Dado que r_k está definido entre variables aleatorias que siguen un mismo proceso, es por eso por lo que se agrega el prefijo *auto*. El índice k es un entero positivo que representa el número de periodos en el que distan dos variables. Además, según Panta (2013) el r_k mide la relación lineal entre las observaciones de la serie de tiempo segregadas por un retraso k

unidades de tiempo, es decir en pocas palabras describe que tan buena es la relación entre el valor presente de la serie con sus valores pasados y la ACF tiene en cuenta los componentes de tendencia, estacionalidad, ciclos y valores residuales. (Bustos, 2019)

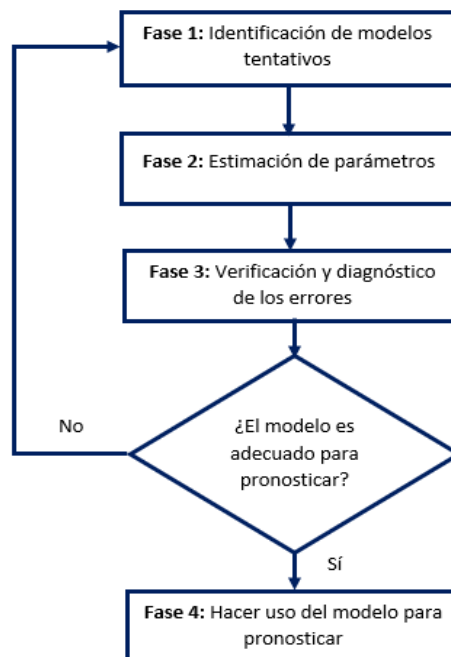
- **Función de autocorrelación parcial**

La función de autocorrelación parcial o por sus siglas en inglés PACF (Partial AutoCorrelation Function) ahora en vez de encontrar correlaciones del presente con valores pasados, básicamente encuentra la correlación de los residuos con el siguiente rezago o valor pasado, pero eliminando los efectos de observaciones intermedias. Por lo que, si existe información que esté dentro de los residuos que pueda incluirse dentro del modelo para el próximo rezago, se podría tener una característica de los valores de los residuos pasados en el modelo.

En la siguiente figura se resumen las fases del proceso iterativo que se debe realizar para crear modelos de pronóstico bajo la metodología Box y Jenkins:

Figura 2.1.

Proceso iterativo de la metodología Box y Jenkins.



Fuente: Elaboración propia

2.2.5.1 Algunas extensiones del modelo ARIMA.

Dentro de la literatura reciente, se han encontrado diversas extensiones del modelo ARIMA que contemplan la estacionalidad de la serie de tiempo, otros que tienen en cuenta el uso de incluir el comportamiento de variables exógenas también como serie de tiempo, o por el contrario utilizar ambas derivaciones en un sólo modelo en caso tal, la serie de tiempo original se ajuste. A continuación, se describen algunos:

- **Modelo Autorregresivo Integrado de Promedio Móvil Estacional (SARIMA)**

Este modelo, como se mencionó anteriormente, es una extensión del modelo ARIMA, en el que se tiene en cuenta una componente estacional. (Baldon, 2019). Según este mismo autor, el modelo presenta los siguientes cuatro parámetros:

P: es el orden estacional del componente autorregresivo.

D: es el orden estacional del componente diferenciado

Q: es el orden estacional del componente de media móvil

m: es el número de periodos por cada ciclo estacional.

Leszko (2020) define la siguiente notación para el modelo SARIMA:

$$SARIMA(p, d, q) \times (P, D, Q)_m$$

En el que los parámetros (p,d,q), corresponden a la componente no estacional de un modelo ARIMA.

- **Modelo Autorregresivo Integrado de Promedio Móvil con variables exógenas (ARIMAX)**

El modelo ARIMAX, como el modelo anterior es otra extensión del modelo ARIMA, el cual se ha utilizado ampliamente en la literatura sobre pronósticos, pero esta vez incluyendo variables exógenas e independientes de la serie de tiempo original. También puede ser visto como un modelo de pronóstico de series de tiempo que utiliza regresión múltiple con un modelo ARIMA y en el que se debe tener en cuenta las correlaciones de los residuales (Wongdhamma, 2016). El autor anterior describe la forma de este modelo así:

$$y_t = \beta x_t + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

Entendiéndose a x_t como la variable exógena en un tiempo t y β un coeficiente que determina la influencia de este factor externo sobre la serie de tiempo.

- **Modelo Autorregresivo Integrado de Promedio Móvil Estacional con variables exógenas (SARIMAX)**

Según Moreno Arévalo & Melo Contreras (2020), un modelo SARIMAX se caracteriza por tener una estructura que contiene los componentes de un modelo SARIMA, pero que además puede capturar información de ciertas variables externas y explicativas que pueden ayudar a predecir y a comprender mucho mejor la variable de interés, siempre y cuando sea una serie univariante, en el que hay una única variable independiente X y una

variable dependiente Y. Este último modelo descrito sobre la metodología de Box y Jenkins es también una extensión del modelo ARIMA clásico.

2.2.6 Metodología Suavizamiento Exponencial

En primera instancia, la metodología de suavizamiento exponencial es utilizada para realizar pronósticos de demanda en un periodo de tiempo determinado. Según Pacheco, J., (s.f) es un método que posee un mecanismo de autocorrección que tiene la capacidad de adaptar los pronósticos en forma contraria a los errores del pasado, lo que significa que tiene en cuenta promedios ponderados del pasado, mostrándose como la evolución del método de promedio móvil ponderado.

Es claro que esta metodología hace parte de los modelos de series de tiempo e involucra pronósticos del último periodo para construir uno nuevo. Así mismo, aplica para todas aquellas series de tiempo que presenten tendencia y estacionalidad.

Por su parte, acorde con Tutoriales, G., (2015) el suavizamiento exponencial tiene un mejor desempeño cuando el patrón histórico de la demanda no evidencia tendencia ni estacionalidad marcada. Esto significa que dado el caso la serie demuestre un comportamiento creciente, el modelo subestimaré la demanda y dado el caso contrario ocurrirá una sobrestimación de esta.

Dentro de esta metodología se encuentran los modelos suavizamiento exponencial simple doble y triple, conocido también este último como Modelo Holt Winter.

2.2.6.1. Modelo de suavizamiento exponencial simple.

Este modelo de predicción se basa en utilizar una constante de suavización y el error del pronóstico pasado para corregir el siguiente valor a calcular en busca de disminuir el error entre los pronósticos y el valor real. Haciendo ajustes siempre en la dirección opuesta al

error. Si se desea predecir el valor siguiente de una serie de tiempo Y_{t+1} que aún no ha sido observado se calcula con las siguientes ecuaciones:

$$\alpha = \frac{2}{n+1}$$

$$F_{t+1} = F_t + \alpha(Y_t - F_t)$$

Siendo

F_{t+1} = El pronóstico en unidades del periodo t

Y_t = Demanda real del periodo t

α = Constante de suavización que toma valores entre 0 y 1

2.2.6.2 Modelo de suavizamiento exponencial doble.

Cuando las series de tiempo presentan tendencia lineal bien marcada este es el modelo más adecuado, como su nombre lo indica se debe calcular dos veces el promedio móvil para actualizar la estimación de la tendencia, y corregir el problema de subestimar la demanda real, utilizando las siguientes ecuaciones:

$$\text{Nivel: } M_t = \alpha Y_t + (1 - \alpha) * (M_{t-1} + T_{t-1})$$

$$\text{Tendencia: } T_t = \beta * (M_t - M_{t-1}) + (1 - \beta)T_{t-1}$$

$$\text{Previsión: } F_{t+n} = M_t + n * T_t$$

Siendo cada uno de los parámetros:

M_t = Estimado del nivel actual

T_t = Estimado de la tendencia

F_{t+n} = Pronóstico para el periodo n el futuro

n = Periodo a pronosticar

t = Periodo actual

α = Constante de suavizamiento para el nivel $0 < \alpha < 1$

β = Constante de suavizamiento para el estimado de la tendencia $0 < \beta < 1$

Con frecuencia los pronósticos requieren ser realizados para cientos de datos lo que se refleja en tiempo computacional significativo pero debido a la sencillez del suavizamiento exponencial doble se requiere poco tiempo y espacio en la computadora además la exactitud es aceptable para la mayor parte de los problemas de pronóstico a corto plazo.

2.2.6.3 Modelo de suavizamiento exponencial triple o Holt-Winter.

Como bien mencionamos anteriormente, este modelo parte de una extensión del modelo Holt o suavizamiento exponencial doble. Rosales, N., (2017) explica que este modelo se divide en dos principales modelos, dependiendo del tipo de estacionalidad que presenta la serie: el modelo multiplicativo estacional el cual, indica que a medida que se incrementan los datos, el patrón estacional también lo hará y el modelo aditivo estacional que es opcional para métodos de descomposición.

Por su parte, Hyndman, R & Athanasopoulos., (2018) definen el método aditivo mediante la ecuación:

$$\text{Pronóstico: } F_{t+m} = (L_t + B_t * m) * S_{t-s+m}$$

Donde L_t , B_t y S_t hacen referencia a los componentes nivel, tendencia y estacionalidad, y se componen a su vez de los parámetros α , β y γ respectivamente. Por su parte m se utiliza para denotar la frecuencia de la estacionalidad. Sus ecuaciones correspondientes son:

$$\text{Nivel: } L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha) * (L_{t-1} + B_{t-1})$$

$$\text{Tendencia: } B_t = \beta * (L_t - L_{t-1}) + (1 - \beta)B_{t-1}$$

$$\text{Estacionalidad: } S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$$

Estacionalidad multiplicativa

$$\text{Nivel: } L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha) * (L_{t-1} + B_{t-1})$$

$$\text{Tendencia: } B_t = \beta * (L_t - L_{t-1}) + (1 - \beta)B_{t-1}$$

$$\text{Estacionalidad: } S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}$$

$$\text{Previsión: } F_{t+m} = (L_t + B_t * m) * S_{t-s+m}$$

2.2.7. Vectores autorregresivos (VAR)

Alexandru et al (2013) establecen que un modelo de Vectores Autorregresivos (VAR) presenta, alternativamente, un sistema de ecuaciones simultáneas en el que cada una de las variables son explicadas por sus propios rezagos y las del resto de variables del sistema. Es decir, no hay restricciones antes, por lo que las variables son tomadas como endógenas. La única información a priori que se incluye está referida al número de rezagos de las variables explicativas que se incorporan en cada ecuación, a partir del análisis de los datos. Esta herramienta se utiliza con la finalidad de esclarecer las relaciones dinámicas que puedan existir entre distintas series de tiempo, y mostrar cuál es el posible comportamiento de las series ante perturbaciones específicas de algunas variables.

Un modelo VAR básico consiste en un conjunto de T variables endógenas $y_k = (y_{k1}, \dots, y_{kt}, \dots, y_{kT})$ para $t = 1, \dots, T$.

El proceso VAR (p) se define entonces como:

$$y_{1t} = \beta_{10} + \beta_{11}y_{1t-1} + \beta_{12}y_{2t-1} + U_{1t}$$

$$y_{2t} = \beta_{20} + \beta_{21}y_{1t-1} + \beta_{22}y_{2t-1} + U_{2t}$$

Para el caso más simple, con dos variables y un rezago

Donde:

y_{1t} es la variable dependiente (TRM)

y_{2t} : es la variable independiente (Precio del petróleo)

β_i para $i = 1, 2, \dots, p$, son matrices de coeficientes, cada una de orden $k \times k$

β : es un vector de constantes de orden $k \times 1$

u_t : es un vector $k \times 1$ de procesos ruido blanco

Genera series de tiempo estacionarias con medias, varianzas y estructura de covarianza invariantes en el tiempo, dados valores iniciales suficientes. Esto se puede verificar evaluando el polinomio característico.

La estabilidad de un proceso VAR se puede analizar considerando el formulario complementario y calculando los valores propios de la matriz de coeficientes.

2.2.8. Redes Neuronales Artificiales (RNAs)

El modelo de Redes Neuronales Artificiales es un modelo aplicable en la metodología de pronóstico para determinar un posible comportamiento de la demanda. Está basado en el funcionamiento del cerebro humano que según Atria Innovation (s.f.) están formadas por un conjunto de nodos o neuronas artificiales conectadas entre sí para transmitir ciertas señales. Entendiéndose que pasan por un proceso macro que cuenta con una entrada y una salida de la información.

En primera instancia es importante mencionar que las neuronas son células eucariotas que reciben, procesan y transmiten información a través de impulsos nerviosos, estas están compuestas por un terminal axónico, un núcleo y dendritas. Estas últimas son las encargadas de recibir la información y la llevan hacia el cuerpo celular, el núcleo contiene todo el material genético y los axones permiten que la electricidad viaje a través de las neuronas, es decir, en esta parte del proceso se realiza la descarga eléctrica que sucede al chocar una neurona con otra. A este proceso se le conoce como sinapsis.

La sinapsis, es el proceso mediante el cual se lleva a cabo la conexión entre dos neuronas, donde la información es transmitida e interpretada. Merkle (2020) afirma que las redes neuronales se componen de neuronas que actúan como unidades básicas del modelo, en el que cada una tiene una entrada que acarrea un peso y tres funciones de salida: la de propagación, activación y función de transferencia. Cada una de estas con un objetivo distinto. La función de propagación, por ejemplo, es una función encargada de realizar la suma producto entre cada entrada y su peso asignado, la de activación modifica la de propagación y la de transferencia se utiliza para medir la salida acorde con la interpretación que se le quiera dar al resultado.

El proceso de redes neuronales artificiales es una imitación de lo que sucede en nuestro cerebro, ya que el modelo propone que una neurona esté conformada por varias capas interconectadas tal como sucede en el cerebro humano.

Ahora bien, Villada, N & Garcia, E (2012) explican que una red neuronal es un sistema que permite establecer una relación lineal o no lineal entre las salidas y las entradas, actuando como el sistema nervioso humano que puede procesar información en paralelo. Una de las ventajas de las RNA, es su capacidad de procesar información incluso de manera más rápida que un computador, pero debido a la rapidez del proceso es poco probable seguir en detalle cada paso a paso de este, lo que genera que sus errores no sean fáciles de ser hallados.

Son utilizadas en mayor medida para la predicción de series temporales y para detectar la no linealidad en la data aun cuando hay presencia de ruido, Villada, N & Garcia, E (2012). Sin embargo, para entender los modelos de redes neuronales es importante mencionar cuáles son sus elementos. Lara, F (s,f.) determina como elementos del esquema de una neurona artificial:

- El elemento receptor: donde llegan una o varias señales de entrada X_i .

- El elemento sumador: realiza la suma de las señales de entrada y las ponderaciones con su Peso W_i . Este elemento se le reconoce con una letra S.
- El elemento de función activadora: lleva a cabo una función no lineal a la salida con el fin de determinar si la neurona se activa para determinar su respectiva salida.
- El elemento de salida: es el encargado de producir la señal de salida.

En este orden de ideas, el modelado de una red neuronal, según Huerta, A et al (2012) está determinado por:


$$w_{ij}, \text{ con } j = 1, \dots, n. \quad (1)$$

$$h_i(x_i w_{i1}, \dots, x_n w_{in}) = \sum_{j=1}^n x_{ij} w_j \quad (2)$$

$$h_i(x_i w_{i1}, \dots, x_n w_{in}) = \sum_{j=1}^n x_{ij} w_j - \theta \quad (3)$$

$$y_i = f_i(h_i) = f_i(\sum_{j=1}^n x_{ij} w_j - \theta_i) \quad (4)$$

Donde, la ecuación (1) hace referencia a las entradas y sus pesos respectivamente, el número (2) a la regla de propagación ya mencionada anteriormente, la cual ha sido definida por las entradas y sus pesos W . Por su parte, la ecuación (3) agrega un parámetro Teta conocido comúnmente como el umbral. Finalmente, la ecuación número (4) hace énfasis a la función de activación y el conjunto de estas ecuaciones se ve reflejado en la estructura de una red neuronal tal como se muestra a continuación:

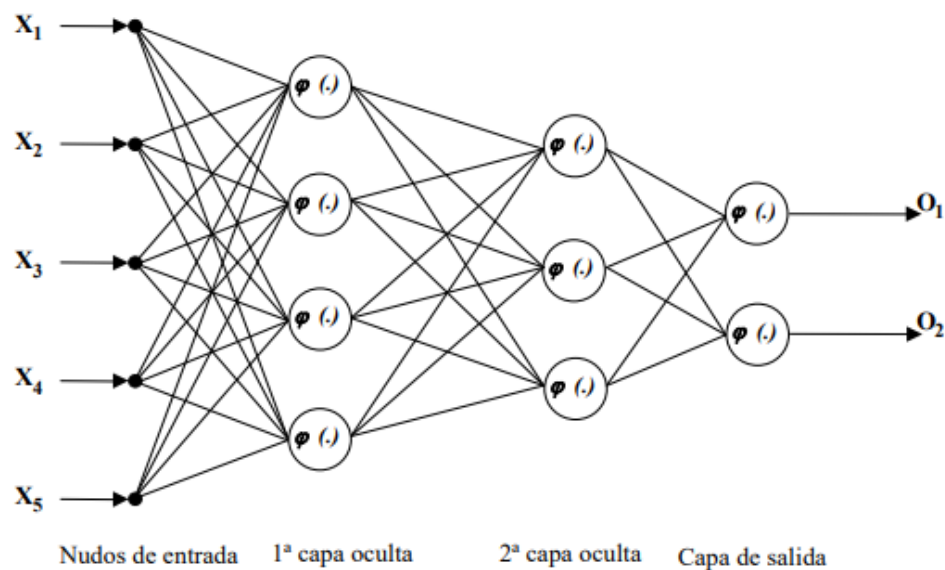
Figura 2.2.*Estructura de una red neuronal artificial*

Fuente: Aplicación de Redes Neuronales para el Pronóstico de Demanda a Corto Plazo[Fotografía], por Sector Electricidad, 2012,

<http://www.sectorelectricidad.com/2625/aplicacion-de-redes-neuronales-para-el-pronostico-de-demanda-a-corto-plazo/>

2.2.8.1 Niveles o capas de una Neurona Artificial

García, O & Olivera, O (2019) afirman que una capa es un conjunto de neuronas cuyas entradas provienen de una capa anterior y sus salidas corresponden a una capa posterior. En este orden de ideas el número de capas depende de lo que el autor diseñe, se pueden tener cuantas salidas se necesiten. Existen tres tipos de capas: las de entradas que contienen los datos de entrada, las ocultas que son las que realizan en mayor medida el proceso y las de salida que muestran los resultados. Cabe mencionar, que no existe una relación 1:1 entre las entradas y las capas ocultas, es probable que exista un menor número de neuronas a la cantidad de entradas que se tengan en el modelo. A mayores neuronas se tengan, y mayores capas, el modelo de predicción realiza más iteraciones y por ende arrojará más precisión, sin embargo, esto, como se mencionó anteriormente, depende de quien diseñe el modelo.

Figura 2.3.*Capas de una red neuronal.*

Fuente: Red neuronal de propagación hacia adelante, de F. Villada, N. Muñoz y E. Garcia, 2012, <https://pdfs.semanticscholar.org/8eaa/e7fcdcdeb6d9566c4bc492c7f2a249900b04.pdf>.

2.2.9. Media móvil autorregresiva vectorial (VARMA)

Los modelos multivariantes de series temporales fueron introducidos por Quenouille (1957); en Tiao y Box (1981), se estudian desde la perspectiva de la metodología Box-Jenkins.

Esta clase de metodología ha sido poco utilizada sin embargo en las investigaciones realizadas ha arrojado buenos resultados cuando se analizan conjuntos de datos mediano y grande dando una mejor precisión del pronóstico de las variables macroeconómicas. Los modelos VARMA están cerrados bajo transformación lineal y marginación, lo que proporciona flexibilidad adicional y un rendimiento de pronóstico potencialmente mejor.

Los modelos de media móvil autorregresiva vectorial (VARMA) proporcionan un marco simple para estudiar las relaciones dinámicas entre variables. No solo son útiles para comprender las relaciones entre adelantamientos y retrasos contemporáneos y habituales, sino

que también son únicos en el sentido de que se pueden utilizar de manera eficiente para detectar mecanismos de retroalimentación entre variables. Además, los efectos de sesgo de las variables omitidas y las ineficiencias de los errores autocorrelacionados se minimizan porque se modelan explícitamente a través de los parámetros autorregresivos. Anggraeni y Kartika (2008)

La técnica de pronóstico es un componente importante de la toma de decisiones porque tiene como objetivo predecir valores de datos en el futuro. Muchos métodos de pronóstico existentes sólo predicen datos de una sola variable y, por lo tanto, no consideran la correlación entre las variables en un conjunto de datos. Realizando una revisión documental hallamos que Wiwik Anggraeni y Leivina Kartika Dew proponen la media móvil autorregresiva vectorial (VARMA) como un método de pronóstico para predecir datos con más de una variable. Este método combina el concepto de regresión, es decir, autorregresivo (VAR) y el método de promedio móvil (VMA) para datos de múltiples variables.

De acuerdo con Anggraeni y Kartika (2008) el primer paso en el método VARMA es probar el estacionario de los datos. El proceso de diferenciación se lleva a cabo para cambiar los datos no estacionarios a estacionarios. Luego se identifica el orden del modelo VARMA de los datos estacionarios, se estiman los parámetros según el orden y se realiza una prueba de cointegración de las variables. El modelo se prueba para evaluar su validez. Si el modelo es válido, la previsión se puede realizar utilizando la fórmula genérica del modelo. Los errores del pronóstico se calculan para evaluar el desempeño del modelo.

Los valores aleatorios se encuentran en el pronóstico del método VARMA. Sin embargo, el error permanece dentro de un cierto intervalo. El intervalo de error está por debajo del 10%, por lo que se puede argumentar que este modelo es muy preciso para predecir los datos.

2.3. Métricas del error

Acorde con uno de los principios básicos de los pronósticos, es necesario medir qué tan asertivo es el modelo realizado, ya que con esto no solamente se mejora el proceso del mismo, sino que también se obtiene más información del desempeño del mismo, permitiendo tomar decisiones inmediatas para quien lo elabora. De esta manera, los pronósticos de demanda son medidos a través de lo que se conoce como métricas del error, de las cuales Chapman, S (2006) menciona:

Error promedio de pronóstico MFE o ME (Mean Forecast Error): su cálculo parte del error medio del pronóstico sobre un periodo específico. Está determinado por la ecuación:

$$MFE = \frac{\sum_{t=1}^n (A_t - F_t)}{n}$$

Donde la ecuación entre paréntesis $(A_t - F_t)$ hace referencia a la diferencia entre el valor de la demanda real y el pronóstico para cualquier periodo. Por ende, esta métrica calcula el promedio de la suma de los errores.

Por otro lado, Martinez, J (2020) define como la raíz cuadrada del Error cuadrático medio como:

RMSE o Root Mean Squared Error: arroja como resultado el error medio al cuadrado, y es principalmente usado en el machine learning. Su cálculo se obtiene de la siguiente manera:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2}$$

Desviación Media Absoluta o MAD (Mean Absolute Deviation): promedia las desviaciones absolutas de los errores del pronóstico. Su ecuación está dada por :

$$MAD = \frac{\sum_{t=1}^n |A_t - F_t|}{n}$$

Por su parte, Manjarres E & Mogollón, J (2017) plantean otras medidas del error como lo son:

Error Cuadrático Medio o MSE (Mean Squared Error): resulta de elevar cada error al cuadrado y luego promediarlos. Tiene la ventaja de castigar más las desviaciones grandes que las pequeñas y su ecuación es la siguiente:

$$MSE = \frac{\sum_{t=1}^n (A_t - F_t)^2}{n}$$

Error Porcentual o PE (Percentage Error): este error resulta de calcular el error absoluto para cada n o periodo de tiempo, dividiéndolo entre el error absoluto y luego multiplicando por cien. De este error, se obtiene también la métrica del *MAPE o Mean Absolute Percentage*

$$MAPE = \frac{\sum_{t=1}^n \frac{(A_t - F_t)}{|A_t|}}{n}$$

2.4. Análisis Bibliográfico

2.4.1. Suavizamiento exponencial triple o Holt Winters

La metodología de suavizamiento exponencial triple es aplicable en series de tiempo que presenten los tres componentes necesarios para llevar a cabo de manera exitosa el pronóstico de la demanda, en este caso, la tendencia, la estacionalidad y los componentes aleatorios. Luego del análisis del comportamiento de los datos de la demanda que se tienen, es necesario identificar el tipo de estacionalidad que estos presentan para generar un pronóstico con los mínimos errores posibles. Estos criterios de selección se resumen en el siguiente cuadro:

Tabla 2.1

Técnicas de predicción según criterios de estacionalidad y tendencia

	Sin estacionalidad		Con estacionalidad	
Sin tendencia	Promedio móvil simple	Suavización exponencial simple	Estacional aditivo	Estacional multiplicativo
Con tendencia	Promedio móvil doble	Suavización exponencial doble	Holt-Winters' Aditivo	Holt-Winters' multiplicativo

Fuente: <http://bdigital.unal.edu.co/71861/1/1053803034.2019.pdf>

Esta metodología ha sido utilizada para predecir pronósticos de demanda, tal como lo propone Gonzalez, F (2018) en el que utiliza un cuadro comparativo con cada uno de los modelos de suavizamiento exponencial, simple, doble y triple y evalúa el error cuadrático medio como criterio de selección. Esta investigación, titulada *Construcción de un modelo para pronosticar la demanda de bicicletas usando series de tiempo*, es una de las tantas demostraciones de la utilidad del método de suavizamiento exponencial, siempre y cuando el comportamiento de los datos presente los componentes mencionados previamente en la literatura.

2.4.2. Redes Neuronales artificiales

El modelo de redes neuronales artificiales o RNA aplicado en métodos de pronóstico es considerado como uno de los posibles métodos aplicables en nuestra investigación ya que debido al comportamiento y la información de la demanda que se tiene, son datos que permiten construir un modelo de pronóstico a corto plazo, lo cual concuerda con una de las ventajas que proponen las RNA. Sin embargo, el periodo de tiempo a pronosticar cobra relevancia en este tipo de metodologías, ya que la forma de abarcar el modelo está compuesta por unas capas que conforman entradas y salidas, y estas dependen directamente del número de periodos que se quiere pronosticar. El modelo propuesto en la figura X de capas de una red neuronal, es un diseño planteado para más de un periodo, en donde la metodología a seguir es

la realización de un primer pronóstico para un periodo 1 que servirá como base para los próximos periodos hasta que se obtengan los resultados deseados, metodología que se llevaría a cabo por los autores del presente trabajo.

Ahora bien, dentro de los criterios de selección para esta metodología se tienen en cuenta los métodos de aprendizaje de las redes neuronales, ya que es la clave fundamental para el diseño de la RNA. En esta investigación, se escogió el aprendizaje por refuerzo como base, en el cual se tiene una entrada conocida, que en este caso serían los datos históricos de las líneas de servicio del contact center y se evalúa la salida con respecto a todo el sistema. Es decir, se realiza una evaluación de los resultados y se proponen mejoras de estos.

Ahora bien, luego de realizar el análisis bibliográfico sobresale la metodología planteada por Salazar, M & Cabrera, M (2007) en su investigación titulada *pronóstico de demanda por medio de redes neuronales*, en la que, de manera similar, proponen una metodología con bases de estadística y matemática para seleccionar los parámetros del modelo. Es esta misma investigación, en la que los autores nombrados anteriormente utilizaron un horizonte de tiempo de 12 meses tomando como modelo la estructura de una RNA ya explicada por los autores del presente proyecto.

2.4.3 Modelos ARIMA y ARIMAX

Dentro de la literatura revisada se encontró que esta metodología es ampliamente usada en varios sectores e industrias. Teniendo en cuenta que la prioridad era que se caracterizaran por ser recientemente publicados, y relacionados con la estimación del flujo de llamadas en empresas del sector del call o contact center, sin embargo también para otras industrias, ya que esta metodología se ha venido utilizando por muchos años y actualmente se han creado una variedad de extensiones, unas más complejas que otras que por el alcance del proyecto sólo será tratada la extensión denominada ARIMAX, dado que como se mostró en los antecedentes existen varios indicadores que son medibles dentro del Contact Center,

como la ocupación, el nivel de servicio, el TMO o AHT (tiempo promedio de la llamada) que son variables a considerar en la influencia del comportamiento de la demanda, asimismo como las horas conectadas, llamadas transferidas, retiros y la demora durante las llamada. Todo esto, abarcando el paso a paso que conlleva la metodología Box y Jenkins para diseñar los modelos de pronóstico ARIMA.

A partir de la revisión de los diferentes artículos relacionados con la predicción de llamadas de atención al cliente del sector contact center en lengua hispana, se destacó el de Osorio y Ochoa (2020), en el que también revisan lo realizado por otros autores dentro de literatura relacionado con la metodología Box y Jenkins y pronóstico de empresas de contact center. De ahí justifican que el uso de esta aporta elementos más robustos a la estimación de la demanda de llamadas que ayudan a mejorar las operaciones y otras medidas internas que atañen costos para la compañía. Los autores diseñaron varios modelos ARIMA que fueron comparados bajo los criterios de: menor error medio porcentual o MPE (en inglés, Mean Percentage Error) para garantizar precisión. Además, se utiliza el criterio del menor valor BIC y el test o prueba estadística de Ljung-Box para descartar correlaciones entre los residuos de cada modelo.

Por otro lado, Kissi et al. (2018) utiliza el modelo ARIMAX para predecir el índice de precios de licitación, debido a la inestabilidad que este presentaba por la situación económica, aspecto que también ocurre dentro del Contact Center dada la coyuntura del 2020 a nivel mundial. En este artículo se implementa el uso de variables exógenas que se dice tiene influencia sobre la variable a pronosticar, a través de la prueba de causalidad de Granger, en el cual se acepta la hipótesis de que alguna variable exógena causa el comportamiento de la variable dependiente. Además para evaluar los modelos utilizan varias métricas de error entre ellas el RMSE.

Baldon (2019) tiene en cuenta para la elección de las métricas la raíz del error

cuadrático medio o por sus siglas en inglés el RMSE (Root Mean Square Error), ya que principalmente, es una de la métricas más utilizadas dentro del campo de los pronósticos, se puede manejar una mejor interpretación porque logra atenuar aquellos errores que son muy altos y que a la hora de utilizar el error cuadrático medio, hace que la interpretación de los errores con esta característica sea más difícil, además de que los penaliza cuando son indeseables, por lo que esta métrica de error será de utilidad usarse para el presente proyecto por su interpretabilidad.

2.4.4. Modelo autorregresivo vectorial (VAR)

“Los modelos VAR son herramientas naturales para la previsión. Su configuración es tal que los valores actuales de un conjunto de variables se explican en parte por los valores pasados de las variables involucradas”. Hashimzade y Thornton (2013) . Siendo de vital importancia para nuestro proyecto que comprende una problemática en la industria BPO y contact que consiste en pronosticar la demanda de llamadas. Este modelo fue planteado por primera vez por Sims (1980) como una extensión de un modelo autorregresivo univariado (AR) añadiéndole de esta forma una característica multivariable en las series de tiempo.

La principal motivación para incluir el modelo de autorregresión vectorial (VAR) es debido a que es uno de los modelos más exitosos, flexibles y fáciles de usar para el análisis de series de tiempo multivariadas, es especialmente útil para describir el comportamiento dinámico de las series de tiempo económicas, financieras y para realizar previsiones, lo que es pertinente en nuestra investigación. A menudo proporciona pronósticos superiores a los de los modelos de series de tiempo univariantes y elaborados modelos de ecuaciones simultáneas basados en la teoría, además son bastante flexibles porque pueden condicionarse a las posibles trayectorias futuras de las variables especificadas en el modelo (Zivot, 2006).

En base a la literatura revisada, se destaca Sims, que toma los principales supuestos que debe cumplir un modelo VAR para generar pronósticos confiables.

- Es un modelo de ecuaciones simultáneas donde cada variable crea sus propios rezagos.
- Separa los efectos pasados que explican al vector de las variables endógenas a través de su pasado o mediante variables autorregresivas.
- La estimación del modelo es sencilla, ya que es posible utilizar el método de los Mínimos Cuadrados Ordinarios(MCO).

Para obtener el número de rezagos óptimos se deben aplicar el criterio de información de Akaike (AIC), el criterio de información de Hannan & Quinn (HQ), el criterio información bayesiana de Schwarz (SC) y el error de predicción final de Akaike (FPE). Estos cuatro criterios se basan en la teoría de la información e indican la información relativa pérdida cuando los datos se ajustan usando diferentes especificaciones (Lütkepohl, 2005).

2.4.5. Análisis y criterios de selección

Posteriormente a la revisión realizada de los métodos seleccionados se procede a realizar una comparación manual en la que se evalúa cada método, con unos factores a tener en cuenta en la selección del más adecuado. Entre esos factores se encuentra el uso, aplicabilidad e implementación del método, el horizonte de tiempo para el que aplica y la experiencia de los autores tal como se muestra en la siguiente tabla.

Tabla 2.2.

Cuadro comparativo de métodos de pronóstico.

Método de pronóstico	Descripción	Uso	Horizonte de tiempo	Experiencia de los autores

Box-Jenkins	Modelo matemático que representa el comportamiento de una serie temporal de datos y permite hacer previsiones únicamente introduciendo el periodo de tiempo correspondiente. Chatfield, (1989)	<p>Su desempeño y precisión varía según la amplitud del horizonte de tiempo. Balconá, M (s,f) afirma que entre las áreas en donde más se ha aplicado este modelo se encuentran la macroeconomía, la demografía, estadísticas públicas y series climáticas.</p> <p>Algunos trabajos aplicados: Pronóstico de precios en el sector de alimentos. Marroquín, G & Chalita, M (2011)</p> <p>Pronóstico del comportamiento inflacionario en países de América del Norte. Munguía, L & Estrada, L (2018)</p>	corto y mediano plazo	Media
Suavizamiento exponencial triple- Holt Winters	Es un método clásico de descomposición en el que la serie suele puede descomponer los componentes en tendencia, factor cíclico, estacionalidad y componente irregular Uriel, E & Muñiz, M. (1993)	<p>Es de fácil implementación cuando la demanda posee el componente de tendencia y estacionalidad. Según Balconá, M Magnano, L & Andreozzi, L (2012) se utiliza para hacer pronósticos de demanda en negocios y empresas.</p> <p>Algunos trabajos aplicados:</p>	corto y mediano plazo.	Alta

		<p>Pronóstico de demanda para una empresa de ventas de neumáticos. Toral, J (2008)</p> <p>Pronóstico de demanda y gestión de inventarios para la planeación de la demanda en el sector textil. Pinedo, C (2020)</p>		
Redes Neuronales Artificiales (RNA)	Una red neuronal puede ser descrita como un modelo de regresión no lineal cuya estructura se inspira en el funcionamiento del sistema nervioso humano. Ríos, G(2008)	<p>Su implementación se ve afectada debido a que no es fácil detectar sus errores. Es utilizado principalmente en el área de finanzas.</p> <p>Pronóstico de demanda de productos farmacéuticos. Zavaleta, E & Rodriguez, E. (2010)</p> <p>Pronóstico de demanda del dinero. Neri, S(1998)</p>	corto plazo	Baja
Vectores Autoregresivos (VAR)	Modelo de ecuaciones simultáneas formado por un sistema de ecuaciones de forma reducida sin restringir, es decir, que los los valores contemporáneos de las variables del modelo están constituidas por un bloque de retardos de cada una de las variables del modelo. Novales, A(.2016)	<p>su implementación se ve limitada en la medida que necesita que la data sea estacionaria. Algunos trabajos aplicados: Ciprian Alexandru, N. C. (2013). Vector autoregressive models using "R". Bucharest. su implementacion http://seaopenresearch.eu/Journals/articles/SPAS_1_5.pdf</p> <p>Eric Zivot, J. W. (2006). Modelos autorregresivos vectoriales para series de tiempo multivariadas. En J. W. Eric Zivot,</p>	mediano y largo plazo	Baja

		Modelos autorregresivos vectoriales para series de tiempo multivariadas. (págs. p 385-429). Springer, Nueva York, NY. https://link.springer.com/chapter/10.1007/978-0-387-32348-0_11		
--	--	--	--	--

Fuente: Elaboración propia.

2.4.6. Selección del método de pronóstico a utilizar

Posteriormente de haber establecido el cuadro comparativo entre los distintos métodos de pronóstico que se revisaron en la literatura, es necesario continuar con la selección de aquel que mejor se ajuste tanto al comportamiento de la demanda, como a los objetivos de los autores. Esto se logrará a través de criterios de selección estipulados, tales como:

- Horizonte de tiempo.
- Comportamiento de los datos.
- Precisión.
- Disponibilidad de la data.
- Errores del pronóstico.

Horizonte de tiempo: dado que la información brindada por el Contact Center tiene una periodicidad diaria, y su proyección es realizada con la información obtenida 7 semanas es decir: un lunes se pronostica con lo sucedido 7 lunes atrás y así sucesivamente, eliminando datos atípicos hasta pronosticar lo que ocurre en una semana, se ha decidido utilizar un horizonte de tiempo de corto plazo que sea semanal, esto con el fin de disminuir la probabilidad de errores altos ya que solo se tiene que pronosticar con un periodo hacia adelante. Este criterio nos permite utilizar las metodologías de Box Jenkins y suavizamiento exponencial.

Comportamiento de los datos: con base en el comportamiento de la línea pospago se

analizan tendencias y estacionalidades, y se observa que actualmente los datos no se ajustan a estos patrones, por lo que se descarta el método de suavizamiento exponencial.

Precisión: bien se sabe que a mayor complejidad tenga el modelo de pronóstico, mayor exactitud entregará en sus resultados, como lo es la metodología de Box Jenkins, sin embargo, para esta investigación será suficiente con la exactitud brindada por metodologías sencillas que se encuentren al alcance de los autores según su experticia, razón por la que este criterio también fue escogido como parte de los factores que permitieran la elección del mejor modelo de pronóstico a utilizar.

Disponibilidad de la data: los autores de esta investigación han tenido a su disposición información brindada de lo corrido del año en curso, y como se mencionó anteriormente, la data se obtuvo con una periodicidad diaria, lo que nos permite seleccionar metodologías que sean de corto y mediano plazo.

Errores del pronóstico: este criterio de selección cobra relevancia en la medida que se trata de buscar el modelo con menor error posible.

2.5. Conclusiones

Finalmente, los modelos a utilizar en esta investigación serán el modelo ARIMA, los modelos ARIMA son, en teoría, los mejores modelos para pronosticar una serie de tiempo. El procedimiento implica ajustar un modelo adecuado, estimar los parámetros y verificar el modelo según Reindolf Anokye (2018) . ARIMAX y VAR, este último ya que es la versión mejorada del método de suavizamiento exponencial. Teniendo en cuenta, las métricas de error mencionadas en el análisis anterior para escoger el modelo que arroje el menor RMSE. En el siguiente capítulo se aplicarán cada uno de los modelos referentes propuestos analizando las diferentes líneas de servicio para determinar la que ha tenido mayor afectación dentro de los pronósticos de la campaña a través de varios criterios estadísticos y visuales que

ayudarán a entender la variabilidad de la serie.

Capítulo III: Diseño de la Propuesta

Los capítulos anteriores permiten que se lleve a cabo la propuesta de diseñar el modelo de pronóstico de demanda de llamadas de un Contact Center en Barranquilla. Habiendo incluido la literatura correspondiente en el marco de referencia, incluyendo modelos de pronóstico más reconocidos y que se encuentren alineados con nuestra propuesta. Este capítulo contiene el análisis de los datos que están divididos en líneas (prepago, pospago, televisión y redes sociales), y el diseño y desarrollo del pronóstico que es fundamental en este proyecto, en donde se explica cada fase para su realización. Se tendrá una descripción de cada línea, y se escogerá una línea de acuerdo con los criterios que se tienen, posteriormente se elabora el pronóstico de llamadas para la línea escogida del Contact Center. Para el análisis del comportamiento actual de las llamadas de la línea pospago las proyecciones se tiene una base de datos suministrada por el Contact Center, que contiene los primeros 8 meses del año 2020. Esta información es utilizada como base para los análisis que se realizan.

Durante el desarrollo del capítulo se describen las fases que componen la realización del modelo de pronóstico comparando varios métodos que por sus características pueden ser aplicados. Una vez concluido el presente capítulo, se tendrá diseñado y explicado el modelo de pronóstico, con un detallado paso a paso para su aplicación y con la presentación de resultados y su análisis.

3.1. Diagnóstico del método actual de pronóstico

El contact center del presente proyecto cuenta con un área o departamento llamado WFM o Workforce Management como se menciona en el marco conceptual del capítulo 2, el cual está encargado de estructurar la planeación de la demanda de llamadas, liderada por un gerente quien revisa y controla periódicamente los procesos que vinculan a esta área. WFM

tiene a su cargo las proyecciones o los pronósticos de los diferentes escenarios de tiempo, desde un horizonte por intervalo de hora hasta planeaciones semanales y mensuales. Además, en esta área estás inmersos en los procesos de planificación de capacidad, programación de personal y gestión en tiempo real.

WFM es el área encargada de entregarle al área de operaciones de la compañía los distintos horizontes de tiempo del comportamiento de la demanda de llamadas de cada día de la semana, de la semana en sí. Sin embargo, ya para planeaciones con un periodo más amplio, como a nivel mensual o anual se tiene en cuenta lo que sucede con otras áreas de la compañía, por ejemplo, cuando se realizan presupuestos anuales por campaña, se tiene en cuenta lo que sucederá durante cada mes del año siguiente. Por otro lado, se cuenta con varios analistas capacitados que realizan los pronósticos de demanda para las diferentes campañas, así como la planeación de capacidad o de requerimiento de personal por día de semana y por semana para que de esta manera se pueda hacer la programación de agentes por skill o habilidad y disponibilidad de tiempo, ya que en la compañía uno de las ventajas se agente o asesor es los horarios flexibles.

WFM cuenta con los datos históricos de las llamadas entrantes, contestadas, abandonadas, los niveles de servicio, AHT, ocupación, llamadas transferidas, horas conectadas y accesibilidad proporcionadas por el cliente o empresa que contrata al Contact center para el servicio de llamadas, esto sería para cada una de las líneas de servicio.

Ahora bien, cada analista del área de Workforce encargado de su campaña deber enviar las proyecciones respectivas teniendo en cuenta lo siguiente:

1. Volumen histórico de tráfico.
2. Tiempo de manejo de llamada (AHT).
3. Distribución del tráfico por intervalos, ajustándose según el peso porcentual histórico

de las últimas semanas.

4. Nivel de servicio.

En los pronósticos de demanda se aseguran sólo de que las anomalías sean eliminadas de los datos históricos para obtener una mayor precisión y de usar los suficientes para predecir tendencias y estacionalidad. Por ejemplo, se realiza la revisión del tráfico histórico de las últimas 7 semanas, es decir un $n=7$, en el que se busca detectar los días atípicos con el fin de obtener una proyección adecuada. Luego de revisar y cambiar los días que no están dentro de la media, se revisa el comportamiento por intervalo con el fin de suavizar las curvas. Si se toma como ejemplo, los últimos 7 lunes por intervalo de media hora y se realiza un promedio simple y ponderado para saber lo que ocurrirá el próximo lunes de la semana y así con cada día de la semana, a cada uno de los intervalos se les asigna una ponderación o porcentaje de las llamadas entrantes sobre el total de llamadas que ocurrieron 7 lunes hacia atrás, para así poder realizar la ponderación con el promedio simple de cada lunes.

Por lo que, para hacer un pronóstico para cada día de la semana se realiza teniendo en cuenta lo que pasa 7 días de la semana atrás, eliminando los datos atípicos. Teniendo en cuenta esto, la empresa posee una metodología para realizar sus pronósticos de corte cuantitativo, sin embargo, la empresa al crecer cada vez más en número de campañas y al ser estas cada vez más variables en el tiempo y a pesar de que tiene en cuenta datos históricos y no sólo percepciones cualitativas de la demanda, el proceso de estimación de la misma ya presenta deficiencias en términos de precisión, de análisis de comportamiento de la demanda, ya que si bien se tiene en cuenta gráficamente el comportamiento de la serie de tiempo de las llamadas, no se analiza su variabilidad en la misma, factor importante para determinar si una línea de servicio tenderá a impactar en la planeación de una línea de servicio, de la campaña y de toda la compañía. Además, al pronosticar una semana de esta manera se llega a caer en

cuenta de los errores por día de semana, es decir, los errores de una semana se estarán teniendo en cuenta los errores de cada día de la semana, lo que hace más impreciso lo que ocurrirá en la semana.

3.2. Análisis del comportamiento de la demanda

- **Línea Prepago**

La línea de servicio Pospago muestra la sucesión de datos que han sido recopilados con una periodicidad diaria por 33 semanas. Esta serie de tiempo recolecta los valores de la demanda de llamadas en intervalos de tiempo generalmente homogéneos como se puede ver en la Figura 3. en la que se representa la serie de tiempo de la línea con varios picos abruptos en el de la demanda de llamadas, de manera más marcada en los meses de Julio a Agosto, además la dispersión a nivel mensual ha sido estable en la mayoría de los meses (Enero a Junio de 2020), dado que las cajas muestran un rango menos amplio durante estos meses concentrando más los datos hacia la media y las posiciones de los cuartiles son similares entre sí (Ver Figura 3.1.), ya el primer cuartil ronda entre las 1400 y 1800 llamadas, exceptuando el mes de Julio que superó las 2000 llamadas, el segundo y tercer cuartil oscila entre las 2000-2100 y 2300-2800 respectivamente, a excepción de Julio y Agosto (Ver Tabla 3.1).



Figura 3.1*Serie de tiempo diario - Línea Prepago**Fuente: Elaboración Propia***Figura 3.2.***Gráfico de cajas y bigotes mensual - Línea Prepago.**Fuente: Elaboración Propia*

Tabla 3.1*Media y cuartiles por mes - Línea Prepago.*

PREPAGO	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto
Media	2029	2326	2742	2112	2433	2234	4139	3110
Q1	1742	1648	1792	1420	1433	1898	2599	1692
Q2	2144	2136	2286	2155	2107	2174	4413	3142
Q3	2314	2585	2858	2494	2393	2555	4875	3897

Fuente: Elaboración Propia

- **Línea Pospago**


La serie de tiempo de la línea Pospago se muestra como una sucesión de datos que han sido recopilados con una periodicidad diaria. Así mismo esta serie de tiempo se presenta como una serie de tiempo discreta, la cual según Coutin, G (2001) ocurre cuando los valores se ofrecen para intervalos de tiempo, generalmente homogéneos y donde representan la magnitud acumulada del estado de la variable durante ese intervalo. Con base en esto, se afirma que la información a la que se tiene acceso no es homogénea en el tiempo, definición que Parra, J & Vicente, J. (2019) hace referencia a datos que mantienen su definición y la medición de la magnitud del objeto de estudio. Ahora bien, así como en la línea de Prepago, en la Figura 3.1, se muestra que esta línea empezó el año con un tráfico de llamadas relativamente bajo hasta mediados del mes de marzo (día 75 en el gráfico de la serie de tiempo) en comparación al resto del año, luego se mantuvo estable hasta el mes de Julio, en el que se dió un incremento abrupto de la demanda y hasta Agosto se ha marcado un tráfico medianamente regular hasta lo que se lleva del este mes.

Lo anterior, se confirma en el gráfico de cajas y bigote por mes se evidencia una marcada variación en la forma de las cajas por grupo de meses, es decir, Enero y Febrero fueron meses con menor dispersión. A partir de Marzo hasta Junio aumentó la variabilidad del tráfico, y en Julio y Agosto, se incrementó aún más, apuntando a que los valores de la

demanda de esta línea no han sido estables en el tiempo (Ver Figura 3.3). Además, si se analiza la posición del cuartil 3 en la Tabla 3.2, este muestra que el 75% de los datos no se ha mantenido en el tiempo, ya que los valores se incrementan y disminuyen, asimismo los valores de la mediana o cuartil 2, distan de la media, mostrando así una marcada diferencia de la distribución de los datos a través del tiempo con respecto a la línea de servicio anterior.

Figura 3.3


Serie de tiempo diario - Línea Pospago.



Fuente: Elaboración Propia

Figura 3.4

Gráfico de cajas y bigotes mensual. - Línea Pospago.



Fuente: Elaboración Propia

Tabla 3.2.

Media y cuartiles por mes - Línea Pospago.

POSPAGO	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto
Media	1372	1256	1794	2333	1838	1640	3141	2711
Q1	723	795	978	1326	1171	1264	1569	1052
Q2	1134	1033	1238	1920	1739	1690	2672	2614
Q3	1347	1416	2545	2992	2357	2021	3770	3172

Fuente: Elaboración Propia

- **Línea de Televisión**


En televisión, se denota una clara estabilidad con estacionalidades en el tráfico hasta mediados del segundo trimestre (Ver Figura 3.5), es decir finalizando el mes de Mayo, denotando así una distribución de los datos más homogénea durante este periodo, sin embargo iniciando mitad de año se evidencia el cambio abrupto de la serie, que puede

deberse a algún factor externo que no hayan contemplado dentro de las operaciones y que no hace parte del comportamiento normal de la serie, además se evidencia el incremento en el tráfico de los días pico finalizando el mes de Junio y este comportamiento se mantiene hasta el final de la serie, mostrando así un aumento en la variabilidad de la misma.


Por otro lado, si se analiza el diagrama de cajas de la serie, en la Figura 3.6 a través de los meses del 2020, la dispersión del tráfico de llamada de Enero y Febrero fue baja, dada la forma tan angosta de la caja, mostrando así una distribución más homogénea de los datos en estos meses, no obstante de Marzo a Mayo se incrementaron los valores de las llamadas ligeramente, aumentando ligeramente así la dispersión de los datos. En el mes de Julio, se marcó un comportamiento similar a los de los meses anteriores y en Junio y Agosto, fueron los meses que marcaron mayor dispersión. Lo anterior, se puede ver también, en el comportamiento del cuartil 2, el cual se asemeja al valor de la media de Enero a Mayo, estos dos valores distan más entre sí (Ver Tabla 3.3).

Figura 3.5

Serie de tiempo diario - Línea Televisión.



Fuente: Elaboración Propia

Figura 3.6.*Gráfico de cajas y bigotes mensual. - Línea Televisión**Fuente: Elaboración Propia***Tabla 3.3.***Media y cuartiles por mes - Línea Televisión.*

TELEVISIÓN	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto
Media	490	394	720	842	904	2377	1251	1656
Q1	364	291	439	549	598	1117	631	715
Q2	480	376	665	798	856	1670	884	1619
Q3	594	504	972	1015	1206	2913	1094	2249

Fuente: Elaboración Propia

- **Línea de Redes Sociales**

Esta línea de servicio, también es claro las marcadas estacionalidades a lo largo del 2020 (Ver Figura. 3.7), sin embargo, la demanda tendió al alza a finales del primer trimestre del año, es decir a finales del mes de marzo, momento en el cual ya estaba declarada la pandemia debido al Covid-19, a pesar de este aumento abrupto del tráfico, la demanda siguió manteniendo ciclos o estaciones. Es importante resaltar que se pasó de tener a partir del primer trimestre del año un tráfico que oscilaba entre 100 y 2.000 llamadas aproximadamente, a pasar a un tráfico que oscila entre 400 y 5.000 llamadas, marcando así un cambio estructural de la serie de tiempo.

Si se analiza, el diagrama de cajas, todos los meses exceptuando Enero y Febrero, evidencia una marcada dispersión de la distribución de los datos, por lo mencionado anteriormente. Es por eso que el mes de Marzo, es el mayor dispersión tiene, ya que se pasó de tener un tráfico de entre 200 a 400 llamadas a más de mil, afectando directamente el comportamiento habitual de la interacciones de esta línea, no obstante si logra visualizar, la disminución de la dispersión de los datos hasta junio, incrementándose de nuevo en Julio y Agosto. El cambio abrupto en las magnitudes del tráfico de esta línea, se muestran en el Tabla 3.4 con la media y los cuartiles.



Figura 3.7.*Serie de tiempo diario - Línea Redes Sociales**Fuente: Elaboración Propia***Figura 3.8.***Gráfico de cajas y bigotes mensual. - Línea Redes Sociales**Fuente: Elaboración Propia*

Tabla 3.4.*Tabla Media y cuartiles por mes - Línea Redes Sociales*

REDES SOCIALES	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto
Media	379	365	1375	2433	2027	2127	2214	2202
Q1	245	262	325	1917	1532	1587	1536	1286
Q2	384	321	1032	2475	2125	2099	2431	2261
Q3	467	412	2211	2813	2319	2468	2711	2891

Fuente: Elaboración Propia

Ahora, si bien el análisis descriptivo anterior para cada una de las líneas, muestra el comportamiento de la variabilidad y dispersión del tráfico a nivel general, si se tiene en cuenta los mostrado en los cuartiles y se calcula el rango intercuartil, el cual no se ve afectado por los valores extremos o atípicos de la distribución de los datos. En la Tabla 3.5, se muestra que a través del tiempo la línea de servicio que ha marcado mayor dispersión superando las 1100 llamadas es Pospago durante los meses de Marzo, Abril, Mayo, Julio y Agosto, cabe aclarar que el color rojo demuestra que entre mayor sea el valor del rango intercuartil en un mes dado, más dispersos son los datos. Por día de semana ocurre similar, la línea de Pospago es la única línea que supera las 2000 llamadas en el rango intercuartil (Ver Tabla 3.6), en los días en los que normalmente hay más tráfico de llamadas, es decir los días lunes y martes. Por lo que teniendo en cuenta esto y el análisis descriptivo anterior del comportamiento de los datos de la línea de Pospago y la heterogeneidad de la distribución de sus datos en el tiempo, es la línea de servicio que se considera, que ha tenido mayor afectación en el tráfico de llamadas, y porque es la que ha tenido mayor decaimiento en los niveles de servicio y mayores índices de ocupación, como se mostraron en los antecedentes de esta investigación, que demuestran que los agentes se están cansando más debido a varios factores, y entre ellos

está el pronóstico de llamadas de esa línea de servicio, al cual se le aplicarán cada uno de los modelos previamente mencionados en el capítulo anterior.

Tabla 3.5.

Rango Intercuartil por mes

	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto
Prepago	572	937,5	1066	1074	960	656,75	2276	2205
Pospago	624	621,5	1567	1666,5	1186	756,5	2201	2119,75
Televisión	230	213	533	466	608	1796,75	463	1533,75
Redes Sociales	222	150	1886	896	787	881	1175	1605

Fuente: Elaboración Propia

Tabla 3.6.

Rango Intercuartil por día de semana

	Lunes	Martes	Miércoles	Jueves	Viernes	Sábado	Domingo
Prepago	1136	1082	1950	998	1871	456	297
Pospago	2043	2139	1946	1398	1553	730	389
Televisión	1098	817	804	716	824	529	154
Redes Sociales	568	805	777	880	993	692	293

Fuente: Elaboración Propia

3.3. Diseño de modelos de pronóstico


Los modelos de pronóstico presentados son realizados mediante la herramienta RStudio, la cual permitió desarrollar todo el procedimiento para el cálculo de los pronósticos.

3.3.1 Método de pronóstico ARIMAX

En el gráfico, para el análisis de cada línea se realizó la serie de tiempo. Se tienen 8 ocho variables (Entrantes, contestadas, nivel de servicio, Tiempo Medio Operativo, horas conectadas, llamadas transferidas, retiros y demora) que se presentan con su respectiva serie, mostrando su comportamiento a lo largo de las semanas.

Figura 3.9.

Gráfico de serie de tiempo para cada variable. - Línea Pospago



Fuente: Elaboración Propia

Un modelo ARIMA normalmente se rige por la forma de ARIMA (p, d, q)

p: es el término autorregresivo

d: es el orden de diferenciación requerido para que los datos lo hagan estacionario

q: es la media móvil término.

Se diferencié la serie 2 veces para proponer el orden del modelo Arima, queda a criterio del analista definir el proceso AR(p) y MA(q) que se adecúe a lo ocurrido en el pasado para la campaña.

Como menciona Jamil (2020) “Para realizar el pronóstico de la serie de tiempo mediante el uso del modelo Arima se puede realizar mediante la identificación, estimación, diagnóstico y pronóstico” (p.3). Primeramente, para comprobar la estacionariedad de los

datos, se realiza una prueba de raíz unitaria para la serie temporal y los resultados de esta prueba muestran si cumplen con la estacionariedad requerida. En caso de que los datos no sean estacionarios, el modelo no se puede estimar, y no se pueden obtener pronósticos. Se tiene que diferenciar los datos repetidamente hasta que se vuelvan estacionarios. El número de veces que se diferencian los datos por su estacionariedad define el orden de diferenciación del modelo, en este caso fueron 2 veces. Existen diferentes tipos de pruebas de raíz unitaria, incluida la prueba de Dickey-Fuller aumentada (ADF), entre otras. Sin embargo, la prueba de raíz unitaria ADF es la usada.


Hay autores que resaltan que:

A través del correlograma de funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) se muestra en forma gráfica y numérica si hay existencia de un patrón de dependencia temporal en los datos de la serie. Se estudian ambas columnas de ACF y PACF y el número de rezagos que se encuentran significativos, ya sea más allá o muy cerca del rango del intervalo de confianza del 95%.

(Jamil, 2020, p .3)

Figura 3.10.


Gráfico de correlación ACF. - Línea Pospago



Fuente: Elaboración Propia

Figura 3.11.

Gráfico de correlación PACF. - Línea Pospago



Fuente: Elaboración Propia

Según Jamil (2020), el número secuencial de rezagos significativos que muestra PACF da el término AR, p , y el mismo que muestra ACF da el término MA, q , del modelo Arima . Una vez identificados los rezagos significativos, se preparan los modelos tentativos Arima (p, d, q). Se desarrollan dos modelos tentativos para realizar pruebas, luego se seleccionará el que se considere más apropiado para el proceso de diagnóstico posterior. La medida de la adecuación del modelo se basa en pocos criterios.

Tabla 3.7.

Tabla comparativa entre variables y p-values.

Variable Exógena	P-values
OCC	0,454
Nivel del servicio	0,1695
AHT	0,05847
Horas conectadas	0,4107
Llamadas transferidas	0,8197
Retiros	0,339
Demora	0,6103

Fuente: Elaboración Propia


Se le aplica la prueba de causalidad de granger a las variables exógenas para saber cuál es la que causa la predicción de la demanda, Según Granger (1969), se debe utilizar la estimación para determinar una relación causal entre dos variables, en el sentido que los valores rezagados de una puedan mejorar la predictibilidad de la otra; sin embargo, la causalidad de Granger no debe ser tomada rigurosamente como una relación de causa efecto entre dos variables. Mediante esta prueba se determina que variable precede a otra a través de una regla de decisión en la que:

No rechace a H_0 si la probabilidad asociada al estadístico F es $>$ que 0,05

Rechace a H_0 si la probabilidad asociada al estadístico F es \leq que 0,05

Figura 3.12.

Gráfico de revisión de los residuales.



Fuente: Elaboración Propia

- Supuesto de independencia

Validando el supuesto de independencia con la prueba Ljung-Box, y con un nivel de significancia del 2,5% no se rechaza la hipótesis nula de que los errores son independientes

- Supuesto de normalidad

Validando si los errores son normales, y no se rechaza la hipótesis nula de que los errores son normales

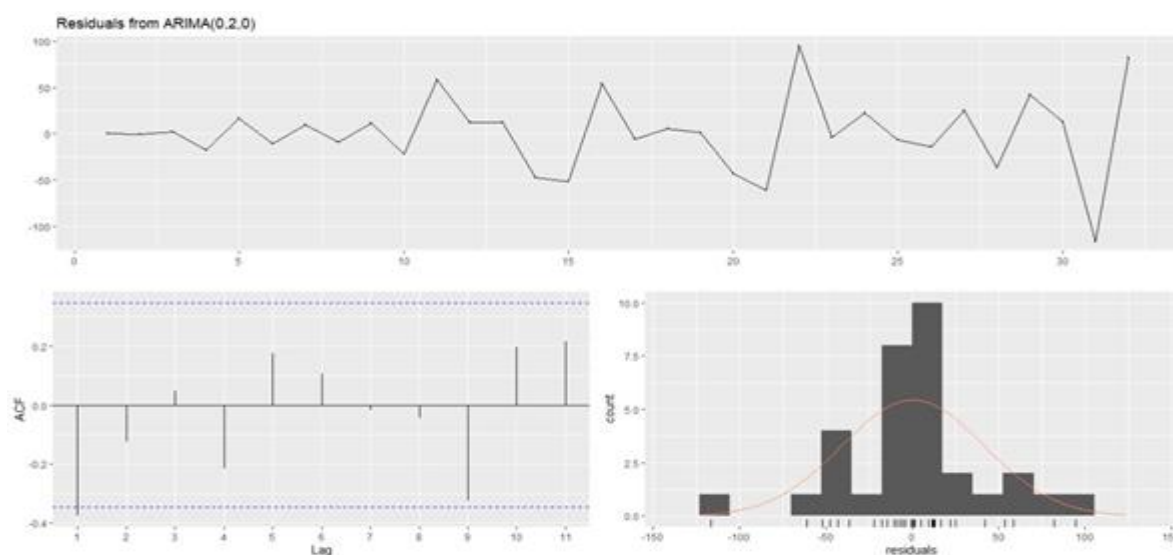
- Supuesto de Homogeneidad

Observando el gráfico de los residuos no se ve ningún patrón por lo que la varianza de los errores es constante.

De la prueba de normalidad para los residuales, el p value de 0.1187 indica que los errores estaban bastante cerca de lo normal sin valores atípicos claros, por tanto, se cumple el supuesto de normalidad. El histograma de residuos confirmó esta suposición, el gráfico de residuos frente a los valores ajustados no mostró ninguna tendencia en la dispersión o patrón por lo que la varianza, esto indicó que el modelo satisface el supuesto de varianza constante según Reindolf Anokye (2018). El gráfico de residuos frente al orden de los datos corroboró que los residuos no estaban correlacionados. Este hecho está respaldado por las estadísticas de Ljung Box que arrojó valor p de 0.02642, no significativo. Por tanto, no se viola el supuesto independiente. Una vez que se mantienen las suposiciones, el modelo puede considerarse válido para la predicción.

Figura 3.13.

Gráfico de revisión de los residuales para la variable exógena.



Fuente: Elaboración Propia

De la prueba de normalidad para los residuales de la variable exógena, el p value de 0.2137 indica que los errores estaban bastante cerca de lo normal sin valores atípicos claros, por tanto, se cumple el supuesto de normalidad. El gráfico de residuos frente a los valores

ajustados no mostró ninguna tendencia en la dispersión o patrón por lo que la varianza. Esto indicó que el modelo satisface el supuesto de varianza constante. El gráfico de residuos frente al orden de los datos corroboró que los residuos no estaban correlacionados. Este hecho está respaldado por las estadísticas de Ljung Box . Por tanto, no se viola el supuesto independiente.


- Pronósticos del modelo Arimax con el modelo escogido (2,2,0)

Después de examinar correctamente el modelo para determinar su idoneidad, se puede procesar más para pronosticar la serie de tiempo. En esta etapa, los valores futuros de la serie son predichos por el modelo basado en el modelo final producido durante la etapa de estimación.

Figura 3.14.

Gráfico de pronósticos del modelo Arimax (2,2,0).

recasts from Regression with ARIMA(2,2,0)




Fuente: Elaboración Propia

3.3.2 Método de pronóstico ARIMA

La modelación de media móvil integrada auto-regresiva (ARIMA) para el análisis de series de tiempo y la predicción basada en datos históricos se considera una de las técnicas más trabajadas por los investigadores, principalmente debido a su fiabilidad para este tipo de datos, es por ello que tomamos esta metodología y la implementamos para hacer parte de nuestros modelos de pronóstico.

Figura 3.15.

Gráfico de revisión de los residuales para modelo Arima (2,1,0).




Fuente: Elaboración Propia

Analizando los residuales, el correlograma muestra diagramas sin patrón para ACF, lo que indica que los datos se han vuelto estacionarios. Al estudiar los residuos de los modelos estimados para verificar el ruido blanco analizamos el correlograma de los residuos. Si se encuentra que el correlograma es “plano”, significa que el modelo seleccionado ya es bueno para el pronóstico, pero si hay algún valor significativo de ACF en los residuos, ese rezago específico debe incluirse en el modelo ARIMA como un término adicional, sin embargo, al

no ser así no se requiere ninguna verificación. De la prueba de normalidad para los residuales, en base al histograma de residuos se indica que los errores estaban bastante cerca de lo normal sin valores atípicos claros, por tanto, se cumple el supuesto de normalidad. El gráfico de residuos frente a los valores ajustados no mostró ninguna tendencia en la dispersión o patrón por lo que esto indicó que el modelo satisface el supuesto de varianza constante. El gráfico de residuos frente al orden de los datos corroboró que los residuos no estaban correlacionados. Por tanto, no se viola el supuesto independiente. Una vez que se mantienen las suposiciones, el modelo puede considerarse válido para la predicción.

Figura 3.16.

Gráfico de pronósticos para modelo ARIMA (2,1,0).



3.3.3 Método de pronóstico VAR

Para realizar este modelo de pronóstico se tomaron los datos de forma diaria, se puede observar, en las series de tiempo. Se utilizó el 80% de los datos como training set, mientras que el 20% restante se utilizó para el cálculo del error RMSE. Las variables tomadas fueron llamadas entrantes y TMO. VAR es un modelo lineal multivariante de series de tiempo donde las variables endógenas en el sistema son funciones de los valores rezagados de todas las

variables endógenas, es decir es esencialmente una generalización del modelo autorregresivo univariado comenzamos instalando los paquetes requeridos y cargándolos para realizar las pruebas de diagnóstico y los pronósticos. Primeramente, juzgamos algunas condiciones iniciales como la no estacionariedad mediante esta prueba.

H0: No hay estacionariedad

H1: Hay estacionariedad.

Para la prueba de Phillips-Perron el p-value nos arroja un valor de .01 lo cual es menor a .05 por lo que con estos resultados vamos a rechazar la hipótesis nula y afirmamos que nuestra serie no cuenta con raíz unitaria, es estacionaria.

Para estimar nuestro modelo Var primero se unen nuestras las variables para crear el sistema. Después de esto, seleccionaremos el orden de retraso óptimo. El comando generará automáticamente el orden de retardo preferido en función de las iteraciones multivariadas de AIC, SBIC, HQIC y FPE. El orden de retardo seleccionado fue el 7 debido a que el AIC es el criterio más determinante.

- Prueba de estabilidad

Para comprobar la estabilidad del modelo revisamos los valores de las raíces del polinomios, los números deben ser menores a 1, dado que todos lo son, se cumple con la condición.

- Prueba de autocorrelación serial en residuales

H0: los residuales no están correlacionados $>.05$

H1: los residuales si están correlacionados $<.05$

No se cumple la condición, los residuales están correlacionados.

- Prueba de Homocedasticidad de la Varianza de los residuales

H0: La varianza de los residuales es constante. $>.05$

H1: La varianza de los residuales no es constante. $<.05$

Se cumple con la condición, la varianza de los residuales es constante.

- Prueba de normalidad de los residuos

H0: los residuos se distribuyen normalmente $>.05$

H1: los residuos no se distribuyen normalmente $<.05$

No se cumple con la condición, los residuales no se distribuyen normalmente.

- Prueba de causalidad de Granger

Comprobamos causalidad de Granger general probando cada variable en el sistema contra todas las demás, en este caso solo hay dos. Determinamos el orden causal. Podría haber una relación de causalidad unidireccional, bidireccional o nula entre las variables.

H0: Entrantes no causa en el sentido de granger a TMO $>.05$

H1: Entrantes si causa en el sentido de granger a TMO $<.05$

Figura 3.17.

Resultados de test de granger para Entrante

`$Granger`

`Granger causality H0: Entrante do not Granger-cause TMO`

`data: VAR object Model1`

`F-Test = 7.8082, df1 = 9, df2 = 320, p-value = 2.055e-10`

`$Instant`

`H0: No instantaneous causality between: Entrante and TMO`

`data: VAR object Model1`

`Chi-squared = 7.7857, df = 1, p-value = 0.005266`

Fuente: Elaboración Propia

H_0 : TMO no causa en el sentido de granger a Entrante $>.05$

H_1 : TMO si causa en el sentido de granger a Entrante $<.05$

Figura 3.18.

Resultados de test de granger para TMO.

\$Granger

Granger causality H_0 : TMO do not Granger-cause Entrante

data: VAR object Model1

F-Test = 1.0355, df1 = 9, df2 = 320, p-value = 0.4113

\$Instant

H_0 : No instantaneous causality between: TMO and Entrante

data: VAR object Model1

Chi-squared = 7.7857, df = 1, p-value = 0.005266

Fuente: Elaboración Propia


Los resultados de la prueba de Granger para determinar la causalidad se presentan y se evidencia causalidad unidireccional en el sentido de Granger de la variable entrantes a la variable TMO.

- Pronóstico mediante VAR

Para realizar la visualización de los pronósticos, generamos un gráfico, estableceremos previamente el horizonte de pronóstico a 48 días.

Figura 3.19.

Gráfico de pronóstico para modelo VAR



Fuente: Elaboración Propia

- Error

Para el cálculo del error del modelo VAR, se tomó parte de los datos como se mencionó anteriormente y los valores pronosticados mediante la herramienta Excel, se calculó el RMSE obteniendo 10287, 3714.

3.4 Selección del modelo

El RMSE fue la métrica escogida, al ser considerada la más robusta, para los anteriores modelos (Arimax y Arima) la herramienta estadística R Studio lo arrojó. Para el modelo VAR se calcula independientemente. Primero se estima la suma de los errores al cuadrado, previamente Se tiene Y que es la variable de respuesta observada, es decir el dato real, y Y^{\wedge} es la predicción realizada por el modelo. Después se promedia al dividir entre el número de residuales o errores, se obtiene la raíz cuadrada y se consigue el RMSE.

Tabla 3.8.

Tabla comparativa de resultados de RMSE entre modelos

RMSE		
ARIMAX	ARIMA	VAR
7934,028	5775,991	10287,3714

Los resultados observados en la tabla 3.8 de este proyecto muestran que los métodos estadísticos para pronosticar arrojan errores bastante grandes dado que los datos que utilizan son reales. Al comparar los resultados del error, obtenemos un RMSE menor para el modelo de pronóstico Arima, es decir pronóstico con mayor precisión.

Capítulo IV: Validación y Análisis de los Resultados

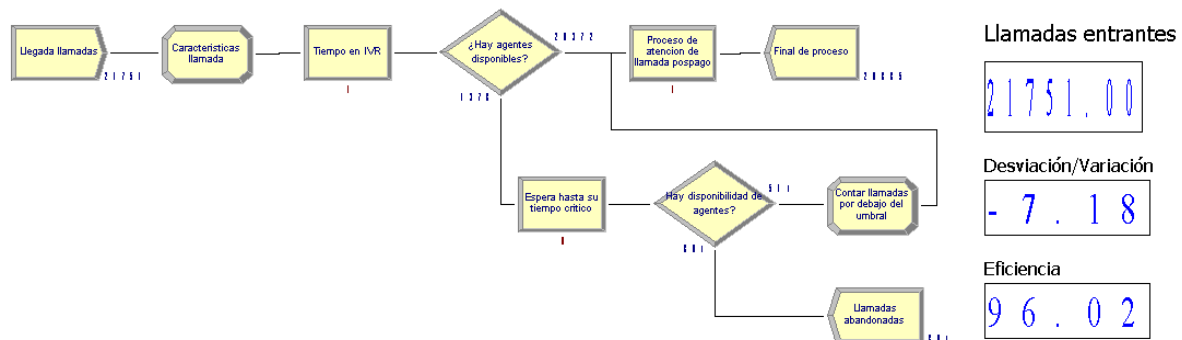
Como se mencionó en el capítulo 1 del presente documento, en este capítulo se validarán los pronósticos del modelo escogido a través de la simulación del proceso de llamadas del Contact Center, utilizando la herramienta de Arena Simulation, todo esto con el fin de contrastar la realidad del comportamiento de la demanda por semana versus los pronósticos propuestas y que así el Contact Center tenga una herramienta que complemente el modelo de pronóstico seleccionado. Posteriormente, se analizarán los resultados utilizando métricas que ya la empresa define como la desviación/variación y la eficiencia.

4.1. Validación de pronósticos

En esta última etapa se construyó el modelo de simulación a partir de entrevistas y hallazgos discutidos con los analistas del Contact Center, en el que se incluyó el abandono de las llamadas y el tiempo de impaciencia calculados con base en el comportamiento de datos históricos. Para el proceso de llegada de las llamadas se tuvo en cuenta la parte autorregresiva que se obtuvo en el modelo de pronóstico semanal escogido ARIMA(2,1,0). La interpretación de este indica que los pronósticos de la demanda de llamadas van a depender de lo que ocurrió 2 semanas atrás, por lo que se usaron los datos de estos 2 períodos para calcular y modelar la tasa de llegada por intervalo de hora promedio (Ver Anexo X) para simular de una manera más real la llegada de las llamadas en una semana, asumiendo un proceso de Poisson, ya que se sabe por los analistas de la compañía y lo revisado en Gutiérrez Vanegas & Florian Lozano (2015) en el que simulaban los arribos o llegada de llamadas como un proceso de Poisson, ya que el comportamiento de la variable aleatoria es de llamadas por intervalo de hora, es decir se está contando un número de eventos ocurridos durante un intervalo de tiempo.

Figura 4.1.

Simulación de proceso de llamadas de línea postpago.



Fuente: Elaboración Propia

Como se muestra en la Figura X. se evidencia la cantidad de llamadas entrantes con base en la demanda de 2 semanas hacia atrás, de esta manera si se contrasta con los pronósticos se ve que existe una desviación/variación, que en el Contact Center se denomina como las $((\text{Llamadas entrantes} - \text{Llamadas pronosticadas}) / \text{Llamadas pronosticadas}) * 100\%$, por lo que con el resultado del modelo de pronóstico ARIMA(2,1,0) se obtiene una desviación/variación de -7.18% para la primera semana pronosticada con una eficiencia del 96,02%, es decir por cada 100 llamadas entrantes se deberían de contestar 96 con la programación de agentes realizada a partir de los mismo periodos hacia atrás en promedio por intervalo de hora (Ver Anexo X). De esta manera, el Contact Center con esta propuesta del modelo de pronóstico podrá valerse de esta herramienta como elemento para presentarlo ante el cliente o empresa contratista como un panorama más preciso de lo que ocurre en la realidad versus la predicción de la demanda, siendo eso una ventaja competitiva para los servicios prestados por el Contact Center

Capítulo 5: Conclusiones y recomendaciones

Actualmente el call center analizado en la ciudad de Barranquilla posee grandes problemas relacionados con su actividad productiva, motivo por el cual se realizó un análisis exhaustivo para identificar estadísticamente qué variables inciden en la planeación operativa de la empresa. Gracias a los resultados obtenidos se pudo concluir que el deficiente funcionamiento de la empresa se debe a un método de pronóstico poco estructurado. Es por esto que el proyecto se enfocó en diseñar un modelo de pronóstico robusto con bases estadísticas sólidas que le permitiera a la empresa ser más precisa en sus predicciones, y brindarle un instrumento innovador como la simulación de procesos discretos para analizar la efectividad de sus procesos, todo esto realizado a la línea de atención pospago, pero replicable a toda la compañía.

Mayores descubrimientos

A lo largo de la investigación se pudo contrastar la información práctica proporcionada por la empresa con la teoría correspondiente a la temática de pronósticos y planeación operativa, donde se encontraron ciertas anomalías en el proceso realizado en la actualidad, ya que esta empresa ejecuta la mayor parte de sus procesos basándose en la experiencia de sus empleados sin efectuar un previo análisis estadístico, es por esto que sus teorías son poco fundamentadas y generan ruido en sus resultados. Esto se puede evidenciar en el modelo de pronóstico y las escasas herramientas que utilizan para su realización, ya que un modelo versátil como ARIMA puede generar mejores resultados acompañado de herramientas de acceso gratuito como RStudio que permiten hacer análisis rápidos optimizando los resultados de la empresa.

Los argumentos que generó la función autoarima en el programa RStudio corroboran que los pronósticos deben realizarse con una frecuencia semanal y dependen de lo que

ocurrió dos semanas atrás y no como sucede en la actualidad donde se utilizan indiscriminadamente siete semanas para realizar el pronóstico diario de la empresa, proceso que aumenta el ruido en las predicciones. Esta función hace una diferenciación de la serie sin tener en cuenta las perturbaciones del pasado, como se evidenció en el modelo Arima(2,1,0) donde la cantidad de llamadas pronosticadas para la semana siguiente a los datos históricos entregados por la empresa fue de 23.574 y la simulación del proceso de atención de llamadas pospago arrojó un total de 21.751 llamadas recibidas con una desviación del -7,18% de lo que demuestra la efectividad del modelo.

Resultados por objetivos

Durante este proyecto de investigación fueron propuestos cinco objetivos específicos que se crearon con la finalidad cumplir con el objetivo general propuesto, el cual es diseñar el método de estimación de demanda para un Contact Center de Barranquilla basado en la comparación de diferentes técnicas de predicción para mejorar el desempeño de la empresa. En primer lugar, se realizó el diagnóstico del método de estimación de la demanda a través de herramientas informáticas, entrevistas y hallazgos, lo que permitió determinar el comportamiento actual de los datos de la empresa.

Para la realización del segundo objetivo, se analizó el comportamiento de la serie de tiempo de la demanda actual de llamadas para identificar la línea de servicio con mayor variabilidad; teniendo en cuenta sus estacionalidades, tendencias y ruidos, que se analizaron por medio de diferentes pruebas estadísticas y diagramas como el de cajas y bigotes, se evidenció una marcada variación en el tráfico y distribución de los datos haciendo uso de la herramienta RStudio. Esto, dio como resultado la selección de la línea pospago como foco de nuestra investigación.

Posteriormente, se procede a definir todos aquellos métodos de pronóstico que se puedan ajustar a los datos suministrados por la empresa para realizar una exhaustiva revisión documental donde se comparan diferentes modelos de pronósticos. Posteriormente en el objetivo número cuatro se procedió a aplicar todas las metodologías de los modelos de pronóstico referentes a la línea de servicio pospago, para seleccionar el modelo Arima(2,1,0) el cual se ajustó a los datos mediante el criterio del error cuadrático medio. Por último, por medio de la herramienta Arena Simulation, se validó el modelo de predicción de demanda mediante una simulación del proceso de entrada de llamadas para realizar el análisis del desempeño del método de pronóstico y se corroboró la importancia del uso de bases estadísticas para mejorar la eficiencia de la compañía en general, ya que este proyecto se puede replicar a cada una de las líneas de la empresa.

La simulación de este proceso presentó una desviación del -7,18% respecto a los datos entrantes y los datos estimados, el aumento en el nivel de servicio en XX, donde se resalta la importancia de incluir las llamadas abandonadas en el proceso de modelado de la empresa para ser más exactos en la planeación operativa de la compañía.

Recomendaciones

Se recomienda a la empresa de call center de la ciudad de Barranquilla, implementar el nuevo método de pronóstico haciendo uso de los parámetros establecidos como la estructura de dependencia de los datos, que implica utilizar dos semanas para realizar los pronósticos, pronosticar semanas enteras para disminuir el ruido entre las predicciones con el fin de mejorar su desempeño, reducir los costos de producción y disminuir la tasa de rotación de empleados dentro de la empresa. Además, se sugiere hacer uso de herramientas innovadoras que faciliten el trabajo de los empleados como RStudio y Arena Simulation que son capaces de modelar el proceso de demanda de forma sencilla para invertir mejor el

tiempo realizando análisis estadísticos que traigan beneficios a la empresa y asimismo una ventaja competitiva frente a otras empresas que ofrecen los mismos servicios en la ciudad de Barranquilla.

Referencias

Alberto Stubbs, E. (2013). Indicadores de desempeño: naturaleza, utilidad y construcción. IBICT - Instituto Brasileiro de Informação em Ciência e Tecnologia.
<https://ezproxy.uninorte.edu.co:6051/es/ereader/unorte/3983?page=1>

Atria innovation (2019) Que son las redes neuronales y sus funciones.
https://www.atriainnovation.com/que-son-las-redes-neuronales-y-sus%20funciones/#%C2%BFCual_es_el_objetivo_de_las_redes_neuronales

Balconá, M. Magnano, L ,Andreozzi, L (2012) Características de los modelos de espacio de estado de innovaciones, con aplicaciones. Recuperado de
https://www.fcecon.unr.edu.ar/web-nueva/sites/default/files/u16/Decimocuartas/blacona_andreozzi_magnano_caracteristicas_de_los_modelos_de_espacio.pdf

Baldon, N. (2019). Time series Forecast of Call volume in Call Centre using Statistical and Machine Learning Methods.

Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2013). Time series analysis: Forecasting and control: Fourth edition. In Time Series Analysis: Forecasting and Control: Fourth Edition. <https://doi.org/10.1002/9781118619193>

Capas de una red neuronal. Nota. Adaptado de Red neuronal de propagación hacia adelante, de F. Villada, N. Muñoz y E. Garcia, 2012.
<https://pdfs.semanticscholar.org/8eaa/e7fcdcdeb6d9566c4bc492c7f2a249900b04.pdf>.

Caro Vasquez, Monica Gabriela & García Guillén. (2017). Atracción de talento humano a un Call Center. Universidad Peruana de Ciencias Aplicadas (UPC), <http://hdl.handle.net/10757/622914>

Chaojie Duan, Varun Grover, Nicholas Roberts & Nagraj (Raju) Balakrishnan (2014) Efectos de valoración empresarial de la decisión de adoptar acuerdos de subcontratación de procesos de negocio gobernados relacionamente, International Journal of Production Research, <https://ezproxy.uninorte.edu.co:2074/doi/citedby/10.1080/00207543.2014.884289?scroll=top&needAccess=true>

Chapman, S. (2006). Planificación y Control de la calidad. México, Pearson Educación.

Chatfield, C (1989) The análisis of Time Series: An introduction. Cuarta edición. Chapman&Hall.

Christopher, A. S. (1980). Macroeconomics and reality. En A. S. Christopher, Econometrica (pág. 48) <https://www.pauldeng.com/pdf/Sims%20macroeconomics%20and%20reality.pdf>

Ciprian Alexandru, N. C. (2013). Vector autoregressive models using "R". Bucharest. http://seaopenresearch.eu/Journals/articles/SPAS_1_5.pdf

Coutin, G (2001) Las series temporales. https://files.sld.cu/prevemi/files/2016/11/series_temporales_2001.pdf

De Arce, R. y Mahía, R. (2003). Modelos Arima. Programa CITUS: Técnicas de Variables Financieras

- Eric Zivot, J. W. (2006). Modelos autorregresivos vectoriales para series de tiempo multivariadas. En J. W. Eric Zivot, Modelos autorregresivos vectoriales para series de tiempo multivariadas. (págs. p 385-429). Springer, Nueva York, NY.
https://link.springer.com/chapter/10.1007/978-0-387-32348-0_11
- Farrera, A (2013) Manual de pronósticos para la toma de decisiones. Monserrate, Mexico. Editorial Digital. Ebook. <http://prod77ms.itesm.mx/podcast/EDTM/P007.pdf>
- Garcia, H (2014) Administración de la producción II. https://es.slideshare.net/ector_03/pronosticos-51204204
- Garcia, O & Olivera, O (2019) Redes neuronales artificiales: qué son y cómo se entrenan. Recuperado de <https://www.xeridia.com/blog/redes-neuronales-artificiales-que-son-y-como-se-entrenan-parte-i>
- Gilfillan, P. (2019, 08). 5 Compelling Reasons Why You Need Workforce Management Software. Workforce Management (Time and Attendance) Excellence Essentials, <https://ezproxy.uninorte.edu.co:2167/docview/2307457374?accountid=41515>
- Granger, C. (1969). Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica*, 37(3), 424-438. doi:10.2307/1912791
<https://www.jstor.org/stable/1912791?seq=1>
- Gutiérrez Vanegas, J. C., & Florián Lozano, D. Y. (2015). Diseño de un Modelo de Simulación para la Evaluación de Alternativas de Mejoramiento para una Empresa del Sector de Tercerización de Servicios Bpo.
- Hanke, J. E., & Reitsch, A. G. (1996). Pronosticos en los Negocios. Production Supervision: Maryland Composition.

Hanke, J. E., & Wichern, D. W. (2006). Pronósticos en los negocios. México: Pearson Educación.

Huerta et al (2012) Aplicación de Redes Neuronales para el Pronóstico de Demanda a Corto Plazo. Sector electricidad. Recuperado de <http://www.sectorelectricidad.com/2625/aplicacion-de-redes-neuronales-para-el-pronostico-de-demanda-a-corto-plazo/>

Hyndman, R. & Athanasopoulos, G (2020) Forecasting, principles and practice, 2nd edition. <https://otexts.com/fpp2/>

Izar, J. (2007). Modelos de pronósticos. Contabilidad Gerencial (pp.32), Edición 1- Capítulo 13. Editorial Trillas
https://www.researchgate.net/publication/303650974_MODELOS_DE_PRONOSTICOS

Jamil, R. (2020). Hydroelectricity consumption forecast for Pakistan using ARIMA modeling and supply-demand analysis for the year 2030. ScienceDirect, 1-10.
<https://ezproxy.uninorte.edu.co:2055/science/article/pii/S0960148120303128?via%3Dihub>

Jiménez, J. (2013). Pronóstico de demanda de llamadas en los call center, utilizando redes neuronales artificiales.

Jimenez, J, Gazques, & Sanchez, R (2006). La capacidad predictiva en los métodos Box Jenkins y Holt Winter: una aplicación al sector turístico

Kissi, E., Adjei-Kumi, T., Amoah, P., & Gyimah, J. (2018). Forecasting construction tender price index in Ghana using autoregressive integrated moving average with

exogenous variables model. *Construction Economics and Building*, 18(1), 70-82.

Lara, F (s,f.) Fundamentos de redes neuronales artificiales. Recuperado de
http://conceptos.sociales.unam.mx/conceptos_final/598trabajo.pdf

Leszko, D. (2020). Time series forecasting for a call center in a Warsaw holding company (Doctoral dissertation).

Línea de servicio (service line) | Área de Vinculación Tecnológica -.

Fundacionsadosky.org.ar. (2020). Retrieved 14 October 2020, from

<http://www.fundacionsadosky.org.ar/avt/glossary/linea-de-servicio-service-line/#:~:text=Conjunto%20consolidado%20y%20estandarizado%20de,o%20%C3%A1rea%20de%20misi%C%B3n%20seleccionada.>

Lütkepohl, H. (2005). *Structural Vector Autoregressive Analysis*. Italy

<https://core.ac.uk/download/pdf/41100689.pdf>

Lütkepohl, H. (2013). "Modelos autorregresivos vectoriales". En *Manual de métodos de investigación y aplicaciones en macroeconomía empírica*. Cheltenham, Reino Unido: Edward Elgar Publishing. doi: <https://doi.org/10.4337/9780857931023.00012>

Marroquin, G & Chalita, L. (2011). Aplicación de la metodología Box-Jenkins para pronósticos de precios en jitomate. *Revista Mex.Cienc.Agric* vol 2. No.4.
http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-09342011000400008

Meneses Bustos, I. V. (2020). Pronóstico de mora par 30 de contactar bajo la metodología Box-Jenkins utilizando una base de datos con periodo 2010–2019.

<https://ezproxy.uninorte.edu.co:5011/insight/content/doi/10.1108/SR-05-2015->

0073/full/html

Moreno Arévalo, M. A., & Melo Contreras, E. A. (2020). Pronóstico de la reserva técnica para una empresa del sector salud EPS-SEM bajo metodología BOX-JENKINS.

Munguía, L & Estrada, L (2018) Modelos de pronóstico a corto plazo sobre el comportamiento inflacionario en países de América del norte aplicando series de tiempo: 2006-2017.

<http://ri.uaemex.mx/bitstream/handle/20.500.11799/95362/Tesis%20MODELOS%20DE%20PRON%20CORTO%20PLAZO%20SOBRE%20EL%20COMPORTAMIENTO%20INFLACIONARIO%20EN%20PA%20SES%20DE%20AM%20RCA%20DEL%20NORTE%20APLICANDO%20SE~1.pdf?sequence=1&isAllowed=y>

Novales, A (2017) Modelos vectoriales autorregresivos (VAR).

<https://www.ucm.es/data/cont/media/www/pag-41459/VAR.pdf>

Osorio Hernández, J. E., & Ángel Ochoa, V. H. (2020). Aplicación del modelo Box-Jenkins en la estimación del flujo de llamadas en servicios de atención al cliente en el sector contact center.

Parra, J & Vicente, J (2019). Analisis de series temporales. http://rstudio-pubs-static.s3.amazonaws.com/562743_b0859a1154aa4954a2779d9b492b8976.html

Paternina, F. (2011). Los call centers y su proyección en Colombia. Dictamen Libre. Vol. 8(13-26). <https://dialnet.unirioja.es/servlet/articulo?codigo=6578917>

Peng, L. Z. (2016). Time series estimation of gas sensor baseline drift using ARMA

and Kalman. Emerald, 34-39.

Pinedo, J. (2020). Propuesta de un modelo de pronóstico de demanda y gestión de inventarios para la planeación de demanda en prendas de vestir juvenil. https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/623528/Pinedo_CJ.pdf?sequence=5

Quenouille, M. H. (1957). The analysis of multiple time-series. New York: Hafner Pub. Co.

Reindolf Anokye, Enoch Acheampong, Isaac Owusu y Edmund Isaac Obeng (2018) Análisis de series de tiempo de la malaria en Kumasi: uso de modelos ARIMA para pronosticar la incidencia futura, Cogent Social Sciences, [4: 1] <https://ezproxy.uninorte.edu.co:2074/doi/full/10.1080/23311886.2018.1461544>

Ríos, G. (2008) Series de tiempo. file:///D:/Users/mpertuz46/Downloads/Series_de_Tiempo.pdf

Rodriguez, S., & Massa, F. (2012). CARACTERIZACIÓN DE LA ESTACIONALIDAD DE LOS COMPONENTES DEL PBI URUGUAYO. Instituto de Estadística, Facultad de Ciencias Económicas y de Administración, Retrieved 14 October 2020, from http://www.iesta.edu.uy/wp-content/uploads/2009/07/DT_12_04.pdf.

Rosales, N (2017) Holt Winters. <https://rpubs.com/nanrosvil/283121>

Salazar, M & Cabrera, R (2007) Pronóstico de demanda por medio de redes neuronales artificiales. Ingenierias, Vol X(35). Recuperado de http://eprints.uanl.mx/10351/1/35_pronostico.pdf

Sarabia Viaña, María Carolina, & Paternina Arboleda, Carlos Daniel. (n.d.). Modelos de simulación para la planeación y programación de operaciones de transporte fluvial. Pregrado en Ingeniería Industrial.

Suárez Bazalar, Raúl (2016). Nivel de calidad del servicio aplicando el modelo SERVQUAL en el Centro de Idiomas de la Universidad Nacional del Callao.

Industrial Data, 19(1),7-16.[fecha de Consulta 14 de Octubre de 2020]. ISSN: 1560-9146. Disponible en: <https://www.redalyc.org/articulo.oa?id=816/81650062002>

Toral, J (2008) Política de inventario con pronósticos de demanda para una empresa de venta de neumáticos.

http://www.tesis.uchile.cl/tesis/uchile/2008/toral_jc/sources/toral_jc.pdf

Uriel, E & Muñoz, M (1993) estadística económica y empresarial. Teoría y ejercicios.

USAID (2008). Ministerio de Industria y Comercio (Producer). Desarrollando el Sector de BPO&O como uno de Clase Mundial.

Villada et al (2012) Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. Informacion tecnologica. Vol 23 (4). Recuperado de <https://pdfs.semanticscholar.org/8eaa/e7fcddeb6d9566c4bc492c7f2a249900b04.pdf>

Villareal, F (2016) Introducción a los pronosticos.

https://www.matematica.uns.edu.ar/uma2016/material/Introduccion_a_los_Modelos_de_Pronosticos.pdf

Wiwik Anggraeni, L. K. (2008). MÉTODO PERAMALAN MENGGUNAKAN VECTOR AUTOREGRESIVO MEDIO EN MOVIMIENTO (VARMA). Scientific

Journal of Information Technology, 8.

<http://juti.if.its.ac.id/index.php/juti/article/view/180/135>

Wongdhamma, W. (2016). Upgrade from ARIMA to ARIMAX to Improve Forecasting Accuracy of Nonlinear Time-Series: Create Your Own Exogenous Variables Using Wavelet Analysis."

Zavaleta, E & Rodriguez, E(2010) Sistema de pronóstico de la demanda de productos farmacéuticos basado en redes neuronales.

<https://core.ac.uk/download/pdf/323350618.pdf>

<https://www.colombiaproductiva.com/CMSPages/GetFile.aspx?guid=d2daa27f-c1a5-491e-b4df-34c8ef450e46>

ANEXOS

Anexo 1. Supuestos para modelo ARIMAX (2,2,0)


Ljung-Box test

data: Residuals from Regression with ARIMA(2,2,0) errors
Q* = 9.227, df = 3, p-value = 0.02642

Model df: 3. Total lags used: 6

shapiro-wilk normality test

data: residuals(modelo)
W = 0.94703, p-value = 0.1187



Anexo 2. Errores para ARIMAX

```
call:
arima(x = seriepos[, 1], order = c(2, 2, 0), xreg = aht)

Coefficients:
      ar1      ar2      TMO
    -0.7307  -0.5787  -28.4085
s.e.    0.1626   0.1532   40.8502


sigma^2 estimated as 67145384: log likelihood = -313.43, aic = 634.86

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set -261.355 7934.028 6268.333 -11.85048 43.96936 1.267825 -0.2335498
```

Anexo 3. Supuestos para modelo para la variable exógena

```
shapiro-wilk normality test

data: residuals(proaht)
W = 0.95605, p-value = 0.2135
```



Ljung-Box test

data: Residuals from ARIMA(0,2,0)
 $Q^* = 9.0679$, $df = 6$, $p\text{-value} = 0.1698$
 Model df: 0. Total lags used: 6

Anexo 4. Pronóstico para modelo ARIMA (2,2,0)

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
33	29127.51	18058.14	40196.88	12198.3682	46056.65
34	28128.82	10241.60	46016.04	772.6737	55484.97
35	34411.25	10051.53	58770.97	-2843.7213	71666.22
36	37331.37	3089.82	71572.91	-15036.5596	89699.29

Anexo 5. Supuestos para modelo para ARIMA (2,1,0)


```


Coefficients:
      ar1      ar2
    -0.4592  -0.4838
s.e.    0.1656   0.1609

sigma^2 estimated as 36698274: log likelihood=-323.38
AIC=652.76  AICc=653.62  BIC=657.16

Training set error measures:
      ME      RMSE      MAE      MPE      MAPE  MASE
Training set 904.7871 5775.991 4085.287 -3.33759 27.67069 NaN
      ACF1
Training set -0.108128
>

```

Anexo 6. Serie de Tiempo para variable Entrante**Anexo 7.** Serie de Tiempo para variable TMO



Anexo 8. Resultado Prueba Phillips-Perron

Phillips-Perron Unit Root Test

```
data: Entrante
Dickey-Fuller Z(alpha) = -122.89, Truncation lag parameter = 4,
p-value = 0.01
alternative hypothesis: stationary
```

Phillips-Perron Unit Root Test

```
data: d$TMO
Dickey-Fuller Z(alpha) = -28.653, Truncation lag parameter = 4,
p-value = 0.01
alternative hypothesis: stationary
```

ARCH (multivariate)

```
data: Residuals of VAR object Model1
Chi-squared = 80.786, df = 81, p-value = 0.4858
```

Anexo 9. Resultado Prueba de estabilidad

VAR Estimation Results:

=====

Endogenous variables: Entrante, TMO

Deterministic variables: const

Sample size: 227

Log Likelihood: -2966.308

Roots of the characteristic polynomial:

0.9598 0.9537 0.9537 0.9125 0.9079 0.9079 0.817 0.7955 0.7955 0.7706 0.7706 0.7584 0.7584 0.6348 0.6348 0.5572 0.5572 0.08099

Call:

VAR(y = v1, p = 9, type = "const", exogen = NULL)

Anexo 10. Prueba de autocorrelación en seriales

Portmanteau Test (asymptotic)

```
data: Residuals of VAR object Model1
Chi-squared = 7.2851, df = 0, p-value < 2.2e-16
```

Anexo 11. Prueba de normalidad

\$Skewness

Skewness only (multivariate)

data: Residuals of VAR object Model1

Chi-squared = 456.06, df = 2, p-value < 2.2e-16

\$Kurtosis

Kurtosis only (multivariate)

data: Residuals of VAR object Model1

Chi-squared = 5251.2, df = 2, p-value < 2.2e-16

AIC(n)	HQ(n)	SC(n)	FPE(n)
7	2	2	7

Anexo 12. Pronósticos para modelo Var

\$Entrante

	fcst	lower	upper	CI
[1,]	3112.255	462.0418	5762.468	2650.213
[2,]	2560.148	-264.8861	5385.181	2825.034
[3,]	2160.729	-671.9646	4993.423	2832.694
[4,]	2056.678	-797.0341	4910.391	2853.712
[5,]	2013.578	-864.0924	4891.248	2877.670
[6,]	2120.125	-788.0729	5028.323	2908.198
[7,]	2461.042	-447.6696	5369.753	2908.711
[8,]	2631.028	-296.9109	5558.967	2927.939
[9,]	2272.605	-662.8546	5208.065	2935.460
[10,]	2171.859	-771.0488	5114.766	2942.907
[11,]	2150.401	-803.5759	5104.378	2953.977
[12,]	2260.032	-694.9051	5214.970	2954.938
[13,]	2303.212	-653.1326	5259.556	2956.344
[14,]	2427.320	-529.7569	5384.397	2957.077
[15,]	2452.980	-510.2147	5416.174	2963.194
[16,]	2332.086	-632.7288	5296.900	2964.815
[17,]	2248.515	-717.3260	5214.356	2965.841
[18,]	2258.879	-709.3906	5227.149	2968.270
[19,]	2312.703	-655.9919	5281.398	2968.695
[20,]	2357.419	-611.3846	5326.222	2968.803
[21,]	2390.668	-578.5557	5359.892	2969.224
[22,]	2388.677	-582.1730	5359.527	2970.850
[23,]	2331.523	-639.9094	5302.956	2971.432
[24,]	2290.360	-681.3086	5262.028	2971.668
[25,]	2297.286	-674.8566	5269.429	2972.143

[26,] 2330.820 -641.4375 5303.077 2972.257
 [27,] 2358.825 -613.5250 5331.174 2972.350
 [28,] 2369.539 -603.0747 5342.152 2972.613
 [29,] 2359.453 -613.6024 5332.509 2973.056
 [30,] 2331.206 -642.0629 5304.476 2973.269
 [31,] 2312.836 -660.5472 5286.219 2973.383
 [32,] 2319.474 -654.0367 5292.985 2973.511
 [33,] 2339.784 -633.7742 5313.343 2973.558
 [34,] 2355.417 -618.2228 5329.056 2973.640
 [35,] 2358.032 -615.7516 5331.817 2973.784
 [36,] 2348.744 -625.1968 5322.685 2973.941
 [37,] 2334.248 -639.7874 5308.283 2974.035
 [38,] 2326.930 -647.1661 5301.026 2974.096
 [39,] 2332.582 -641.5587 5306.722 2974.140
 [40,] 2344.398 -629.7708 5318.568 2974.169
 [41,] 2352.343 -621.8817 5326.568 2974.225
 [42,] 2351.960 -622.3399 5326.260 2974.300
 [43,] 2345.384 -628.9825 5319.750 2974.366
 [44,] 2337.993 -636.4190 5312.404 2974.412
 [45,] 2335.626 -638.8167 5310.070 2974.443
 [46,] 2339.869 -634.5951 5314.333 2974.464
 [47,] 2346.524 -627.9606 5321.009 2974.485
 [48,] 2350.231 -624.2871 5324.749 2974.518

Anexo 13. Tasas de llegada de llamadas y requerido de agentes a partir de lo ocurrido 2 semanas atrás con la demanda

Hora Inicio	Hora Fin	Llamadas	Requerido
12:00:00 a. m.	1:00:00 a. m.	5	0
1:00:00 a. m.	2:00:00 a. m.	1	3
2:00:00 a. m.	3:00:00 a. m.	1	1
3:00:00 a. m.	4:00:00 a. m.	1	2
4:00:00 a. m.	5:00:00 a. m.	1	1
5:00:00 a. m.	6:00:00 a. m.	22	2
6:00:00 a. m.	7:00:00 a. m.	37	2
7:00:00 a. m.	8:00:00 a. m.	61	5
8:00:00 a. m.	9:00:00 a. m.	181	10
9:00:00 a. m.	10:00:00 a. m.	261	28
10:00:00 a. m.	11:00:00 a. m.	303	46
11:00:00 a. m.	12:00:00 p. m.	314	60
12:00:00 p. m.	1:00:00 p. m.	298	34
1:00:00 p. m.	2:00:00 p. m.	284	59
2:00:00 p. m.	3:00:00 p. m.	268	55
3:00:00 p. m.	4:00:00 p. m.	247	54
4:00:00 p. m.	5:00:00 p. m.	247	50
5:00:00 p. m.	6:00:00 p. m.	180	45
6:00:00 p. m.	7:00:00 p. m.	146	37
7:00:00 p. m.	8:00:00 p. m.	105	31
8:00:00 p. m.	9:00:00 p. m.	71	24
9:00:00 p. m.	10:00:00 p. m.	40	12
10:00:00 p. m.	11:00:00 p. m.	26	14
11:00:00 p. m.	12:00:00 a. m.	15	6

Anexo 13. Dashboard con resultados

